

최종보고서(일반과제용)										보안등급	
										일반[✓], 보안[]	
중정기관양행명	국토교통부				사업명	사업명		국토교통기술촉진연구사업			
전문기관명	국토교통과학기술진흥원				사업명	내역사업명		국토교통기술혁신연구 (사회이슈해결 유형)			
공고번호	공고-제2호				연구개발과제번호		21CTAP-C153176-03				
국가과학기술 표준분류	EI1101		30%	EE0202		30%	EE0108	20%	EI1202	20%	
연구주제	(대분류) 더불어민주당			(중분류) 사회통합			(소분류) 정보격차				
연구개발과제명	국문	교량의 실시간 거동예측 및 건전도 평가를 위한 인공지능 기술 개발									
	영문	AI technology development for real-time behavior predictions and health evaluations of bridges									
주관연구기관	기관명	연세대학교 산학협력단				사업자등록번호		110-82-10500			
	주소	(03722) 서울특별시 서대문구 연세로 50 (신촌동, 연세대학교)				법인등록번호		274171-0006247			
주관연구책임자	성명	김문겸				직위		연구교수			
	연락처	직장전화	-				휴대전화		010-5232-2803		
		전자우편	applymkk@yonsei.ac.kr				국가연구자번호		1008 3239		
연구개발기간	전체	2019. 04. 19 - 2021. 12. 31(2년 9개월)									
	1년차	2019. 04. 19 - 2019. 12. 31(8개월)									
	2년차	2020. 01. 01 - 2020. 12. 31(12개월)									
	3년차	2021. 01. 01 - 2021. 12. 31(12개월)									
연구개발비 (단위 : 천원)	정부지원 연구개발비	기관부담 연구개발비		그 외 기관 등의 지원금 지방자치단체 기타()				합계		연구개발비 외 지원금	
	현금	현금	현물	현금	현물	현금	현물	현금	현물	합계	
총계	600,000	-	-	-	-	-	-	600,000	-	-	
1년차	134,000	-	-	-	-	-	-	134,000	-	-	
2년차	135,000	-	-	-	-	-	-	135,000	-	-	
3년차	331,000	-	-	-	-	-	-	331,000	-	-	
공동연구기관 등	기관명	책임자	직위	휴대전화		전자우편		비고			
	위탁연구기관	(주)에이팩스소프트	김도훈	대표	010-4230-7513	dhoonkim@apexsoft.co.kr		역할	기관유형		
연구개발담당자 실무담당자	성명	이정훈				직위		박사과정			
	연락처	직장전화	02-2123-7490				휴대전화		010-9150-6756		
		전자우편	oosi87@yonsei.ac.kr				국가연구자번호		1132 0187		

이 최종보고서에 기재된 내용이 사실임을 확인하며, 만약 사실이 아닌 경우 관련 법령 및 규정에 따라 제재 처분 등의 불이익도 감수하겠습니다.

2022 년 03 월 18 일

연구책임자 :

김문겸



주관연구개발기관의 장 : 연세대학교 산학협력단

김지현



위탁연구개발기관의 장 : (주)에이팩스소프트

김도훈



국토교통과학기술진흥원장 귀하

< 요약 문 >

사업명		국토교통기술촉진연구사업			연구개발과제번호		21CTAP-C153176-03			
내역사업명		국토교통기술혁신연구								
국가과학기술표준분류		EI1101	30%	EE0202		30%	EE0108	20%	EI1202	20%
연구주제		(대분류) 더불어사는어울림사회		(중분류) 사회통합			(소분류) 정보격차			
연구개발과제명		교량의 실시간 거동예측 및 건전도 평가를 위한 인공지능 기술 개발								
전체 연구개발기간		2019. 04. 19 - 2021. 12. 31(2년 9개월)								
총 연구개발비		총 600,000 천원 (정부지원연구개발비 : 600,000 천원, 기관부담연구개발비 : - 천원, 지방자치단체 : - 천원, 그 외 지원금 : - 천원)								
연구개발단계		기초[] 응용[✓] 개발[] 기타(위 3가지에 해당되지 않는 경우)[]			기술성숙도		착수시점 기준(3, 4) 종료시점 목표(7)			
연구개발과제 유형		지정공모 [] 자유공모 [✓]								
연구개발과제 특성		사회이슈 해결								
연구 개발 목표 및 내용	최종 목표		○ 기개발하여 이론적으로 검증된 알고리즘(인공 지능을 활용한 구조물의 실시간 거동예측)을 실제 거더 교량에 적용해보는 실험 ○ 공용중인 교량에 적용 가능한 인공 지능형 실시간 거동 예측 및 건전성 평가 프로그램 개발							
	1년차	목표	○ 주관연구기관(연세대학교): AI 활용 실제 거더 교량의 실시간 거동 예측 가능성 검증 ○ 위탁연구기관(에이펙스소프트): AI와 연동된 거동 예측 GUI 프로그램 개발							
		내용	○ 기개발된 AI 활용한 교량의 실시간 거동 예측 방법을 실제 교량(PSC I형 교량, 경간 30m)에 시험 계획 있음 (측방향 변형률 계측, 수직방향 처짐 예측) ○ 실제 교량 수치 해석 - 정적 하중(트럭하중) 또는 동적 하중을 실제 교량에 재하하여 변위 및 변형률 등을 계측 후, 수치 해석결과와의 비교를 통하여 수치 해석 모델 검증 계획 (필요에 따라 보정 가능. 해석 모델로부터 획득된 데이터의 신뢰성 확보) ○ 다양한 차량 하중을 재하한 수치 해석 결과(변형률, 처짐) data를 이용하여 인공 지능(인공 신경망) 학습 ○ 차량하중이 지날 때 계측된 교량의 처짐과 인공 지능이 예측한 처짐과의 비교를 통하여 AI활용한 실제 교량의 실시간 거동 예측 가능성 실험적 증명 ○ 학습된 인공 지능 모델과 인터페이스 가능한 연동 모듈 개발 ○ 실제 계측된 변형률 데이터로부터 거동을 시각적으로 보여주는 시뮬레이션 모듈 개발							
	2년차	목표	○ 주관연구기관(연세대학교): AI 활용 예측된 거동 바탕으로 건전성 평가 알고리즘 개발 ○ 위탁연구기관(에이펙스소프트): GUI 기반의 건전성 평가 시뮬레이션 프로그램 개발							

	3년차	내용	○ 거더 교량 수치 모델에 결함을 반영하여 수치 해석 수행 ○ 해석 결과로부터 얻을 수 있는 다양한 데이터를 이용하여 AI 학습 (변형률, 변위, 가속도, 속도, 경사도 등) ○ AI가 예측한 데이터를 이용하여 교량의 결함 정도, 위치 등 예측 알고리즘 개발 ○ AI 활용하여 실시간 거동 및 실시간 건전성 평가를 동시에 수행하는 알고리즘 개발 ○ 인공지능 연계 모듈 고도화 - 다양한 계측값과 예측값으로 학습된 인공 지능 모델들과 연동할 수 있도록 멀티 인터페이스 구축 (ex) 계측값 : 변형률, 예측값 : 처짐, 가속도 경우, (① 변형률 → 처짐 ② 변형률 → 가속도, 총 2개의 인공지능 필요) ○ 시각화 모듈 고도화 - 시뮬레이션 프로그램에서 원하는 계측값과 예측값 모두 확인할 수 있도록 개발																			
		목표	○ 주관연구기관(연세대학교): 개발된 프로그램의 구조물 적용 및 검증 ○ 위탁연구기관((주)에이펙스소프트): 상용화 수준의 통합 모니터링 시스템 개발																			
		내용	○ 예측된 거동 및 결함 등을 바탕으로 실시간 구조물의 건전도 정량화하는 기법 개발 ○ 최종적으로 개발된 프로그램을 이용하여 구조물에 적용 및 검증 ○ 검증 결과를 바탕으로 오차 및 알고리즘 수정 ○ 인공지능 연계 모듈 고도화 - 구조물의 건전도를 정량화 인공지능 모델을 탑재할 수 있도록 프로그램 개발 ○ 통합 모니터링 시스템 구축 - 구조물의 계측값과 예측값, 통합진단을 동시에 서비스 할 수 있는 통합모니터링 시스템 개발																			
연구개발성과			<table><tr><th>구분</th><th>논문</th><th>특허</th><th>소프트웨어</th><th>인력양성</th></tr><tr><td>예상성과 (Y)</td><td>국외 SCI :4/3 국외 비SCI : 0/2 국내 : 0/3</td><td>국내 2/3</td><td>3/3</td><td>석사 1/3 박사 3/3</td></tr><tr><td>초과 및 진행 중 성과</td><td>국외 SCI 1편 게재 완료 (초과성과) 국외 SCI 1편 투고 완료 (초과성과) 국내 논문 3편 작성 중</td><td>건전성 평가 방법으로 특허 출원 준비 중</td><td></td><td>2022-1학기 1명 박사 졸업 예정</td></tr></table>					구분	논문	특허	소프트웨어	인력양성	예상성과 (Y)	국외 SCI :4/3 국외 비SCI : 0/2 국내 : 0/3	국내 2/3	3/3	석사 1/3 박사 3/3	초과 및 진행 중 성과	국외 SCI 1편 게재 완료 (초과성과) 국외 SCI 1편 투고 완료 (초과성과) 국내 논문 3편 작성 중	건전성 평가 방법으로 특허 출원 준비 중		2022-1학기 1명 박사 졸업 예정
구분	논문	특허	소프트웨어	인력양성																		
예상성과 (Y)	국외 SCI :4/3 국외 비SCI : 0/2 국내 : 0/3	국내 2/3	3/3	석사 1/3 박사 3/3																		
초과 및 진행 중 성과	국외 SCI 1편 게재 완료 (초과성과) 국외 SCI 1편 투고 완료 (초과성과) 국내 논문 3편 작성 중	건전성 평가 방법으로 특허 출원 준비 중		2022-1학기 1명 박사 졸업 예정																		
연구개발성과 활용방안 및 기대효과			○ 개발된 모니터링 시스템 다양한 실제 구조물에 적용 ○ 개발된 프로그램 실용화 및 사업화 ○ 모바일 장비를 이용한 모니터링 시스템에 대한 후속 연구 ○ 모니터링 비용 감소 및 사회 안전성 증가																			
연구개발성과의 비공개여부 및 사유			해당없음																			

연구개발성과의 등록· 기탁 건수	논문	특허	보고서 원문	연구 시설· 장비	기술 요약 정보	소프트 웨어	표준	생명자원		화합물	신품종	
								생명 정보	생물 자원		정보	실물
	4	2	-	-	-	3	-	-	-	-	-	-
연구시설·장비 종합정보시스템 등록 현황	구입기관	연구시설· 장비명		규격 (모델명)	수량	구입 연월일	구입가격 (천원)	구입처 (전화)	비고 (설치장 소)	ZEUS 등록번호		
	-	-		-	-	-	-	-	-	-		
국문핵심어 (5개 이내)	인공 지능		교량		거동예측		건전성 평가		GUI프로그램 개발			
영문핵심어 (5개 이내)	Artificial intelligence		Bridge		Behavior prediction		Health evaluation		Development of GUI program			

< 목 차 >

1. 연구개발과제의 개요	01
2. 연구개발과제의 수행 과정 및 수행내용	05
3. 연구개발과제의 수행 결과 및 목표 달성 정도	137
4. 목표 미달 시 원인분석	147
5. 연구개발성과 및 관련 분야에 대한 기여 정도	148
6. 연구개발성과의 관리 및 활용 계획	150
7. 참고 문헌	151

별첨자료(성과 증빙자료 등)

1. 연구개발과제의 개요

1-1 연구개발 필요성

1) 사회적 필요성 : 안전의식 증가, 인명피해 예방

- 시간에 따른 구조물의 거동을 파악하고, 이로부터 구조물 상태를 판단하는 것을 건전성 평가라 함.
- 시민들의 안전의식은 점차 증가해가고, 불의의 사고로 인한 인명피해를 예방하기 위하여 실시간 거동 분석 및 건전성 평가는 매우 중요한 기술이라 판단됨.
- 인프라구조물의 수가 증가하고, 기존 구조물의 노후화가 진행됨에 따라 구조물이 위험적인 상황에 노출 될 빈도 및 가능성은 점차적으로 높아지고 있으며 이로 인해 구조물의 거동분석 및 건전성 평가에 대한 중요성 또한 높아지고 있음.
- 이러한 구조물이 노후화 되면 일반적으로 새로운 구조물로 대체할 수 있지만, 이는 비용적인 손실 뿐 아니라, 수많은 사람들이 사용하는 구조물을 일정 기간 사용하지 못하게 됨으로써 막대한 사회적·경제적 손실을 야기할 수 있음.



성수대교 붕괴(1994, 대한민국 서울)



모란디 교량 붕괴(2018, 이탈리아 제노바)

항목	기존 건전성 평가 방법	제안한 AI 기술 건전성 평가 방법
계측장비(계측데이터)	○ 변형률계, 가속도계, 경사계 등 다수·다양한 계측장비 필요	○ 계측에 용이하고 경제성을 확보한 소수의 계측장비 필요
데이터 분석	○ 계측 데이터 = 필요데이터 (다른형태의 데이터 전환 어려움) ○ 거동분석에 많은 시간 소요 ○ 많은 양의 계측 데이터 필요	○ 계측 데이터 개수 << 예측 데이터 개수 (계측 위치 뿐만 아니라, 교량 전체적인 거동 예측 가능) ○ AI활용 여러 형태 필요데이터로 전환 가능 ○ 실시간 거동 분석 가능 ○ 적은 양의 계측 데이터 요구
건전성 평가	○ 대량 데이터 유입과 데이터 경향 분석 ○ 구조 해석, 전문가 의견 등으로 평가 (많은 시간 소요, 주관적 판단) ○ 주기적인 건전성 평가	○ AI 기반 데이터 분석을 통한 건전성 평가에 필요한 시간 효율성 향상 ○ 결함 종류, 위치, 크기 파악에 있어 높은 정확도 및 반복성 확보 ○ 실시간 건전성 평가

2) 기술적 필요성 : 데이터의 폭넓은 활용, 정확한 예측, 모든 유형의 교량 (실교량 및 Mock-up 모형)에 적용 가능

- 건전성 평가는 1) 센서 시스템 구축 2) 데이터 처리(데이터 획득, 전달, 저장) 3) 데이터를 이용한 건전성 평가로 이루어져 있음.
- 센서 시스템의 경우 예전의 유선 케이블에서 현재는 무선 센서 시스템을 구축하여 인터넷을 통하여 효율적으로 데이터를 관리하고, 동시에 여러 기관과 정보를 공유할 수 있는 상황임.
- 기존의 건전성 평가를 위한 기술 개발은 주로 센서 시스템의 개발에만 초점이 맞추어져 있음.
- 하지만 이렇게 센서로부터 수집된 계측데이터를 이용하여 거동을 분석하고, 건전성을 평가하는 데는 상당히 많은 데이터 처리 시간이 소요되고 있는 상황임.
- 이에 따라 자연재해나, 노후화 등으로 인한 위험에 처한 구조물의 골든 타임을 놓쳐 큰 인명피해 사고로 이어지는 결과를 초래할 수가 있음.
- 따라서 본 연구에서는 계측데이터를 다양한 형태의 건전성 평가 데이터로 전환하여 즉각적으로 구조물의 손상 및 거동 변화를 분석하고, 이를 높은 정확도로 반복할 수 있는 AI 기반 건전성 평가 기법을 제안함.
- 본 연구에서 제안하는 방법은 유형, 경간, 크기에 상관없이 모든 교량 (예: 실교량, 모형 교량, mock-up 모형 등)에 적용이 가능함.
- 특히, 교통량이 매우 많은 대형 교량에 대하여, 본 연구에서 제안한 방법을 적용한다면 높은 유지관리 비용이 필요한 기존의 유/무선 센서 배치없이, 단일 종류의 센서 사용만으로도 교량의 손상 상태 및 손상 위치 파악을 높은 정확도로 실현할 수 있을 것으로 판단됨.


3) 경제적 필요성 : 유지·보수 비용 감소, 센서 개수 감소에 의한 경제성 확보

- 적절한 유지·보수 작업을 통하여 노후화 구조물의 가용 수명을 연장하고자 함.
- 건전성 평가 효과는 유지·보수 비용 25%, 수명주기 비용을 10% 감소시킬 수 있는 것으로 보고되고 있음.
- 또한, 구조물에 배치될 센서의 개수 및 위치를 최적화함으로써 계측 센서의 비용을 획기적으로 줄일 수 있음.
- 예를 들어, 기존 건전성 평가에 필요했던 많은 양의 변형을 게이지, 가속도, 경사계 등의 센서 설치 대신 최소한의 변형을 게이지 설치만으로도 가속도, 경사, 처짐 등과 같은 구조물의 손상 및 강성 저하 등과 관련한 데이터를 산출하고 이를 통해 경제적이고 효율적인 건전성 평가를 실시할 수 있음.

1-2 연구 개발의 목표

1) 연구개발과제의 최종 목표

연구의 최종목표	연구자가 기개발하여 이론적으로 검증된 알고리즘(인공 지능을 활용한 구조물의 실시간 거동예측)을 실제 거더 교량에 적용하여 실험적으로 확인하고 공용중인 거더 교량에 적용할 수 있는 인공지능형 실시간 건전성 평가 시스템 개발
목표 달성을 위한 연구개발 내용	○ AI 기법 활용하여 교량의 실시간 거동 예측 기술 검증 위한 실물 실험 ○ 검증된 AI 기법 활용 교량의 거동 예측 기술을 발전시켜 실제 구조물의 건전성을 평가할 수 있는 알고리즘 개발 ○ 개발된 AI 기법 활용 시스템을 실제 교량에 적용 및 검증 ○ 『인공 지능형 실시간 건전성 평가 시스템』의 실용화 가능한 통합 GUI 프로그램 개발



제안한 연구에 적용될 AI형 건전성 평가 시스템 흐름도

2) 연구개발과제의 연차별 목표

	1 차년도	2 차년도	3 차년도
주관 기관	- 개발된 AI 기술의 실제 교량 실험을 통한 검증 - 계측된 변형률로부터 실시간 거동(처짐) 예측	- 건전성 평가 알고리즘 개발 - 교량의 결함 예측 - 교량의 실시간 건전성 정량적인 평가	- 개발된 프로그램 기술시범 - 공용중인 교량에 개발된 프로그램 적용한 시범 - 프로그램 수정 및 보완
위탁 기관	- 거동예측 GUI 프로그램 개발 - 인공지능과 인터페이스 가능한 연동 모듈 개발	- 건전성 평가 프로그램 개발 - 인공지능 연계 및 시각화 모듈 고도화	- 통합 모니터링 시스템 개발 - 상용화 가능한 프로그램 개발

기관별 연구 개발 목표와 주요 내용

구분	연구개발목표	핵심 연구개발성과 (연구개발성과물)	현재 국내·외 기술수준	연구개발 목표치	목표치 설정 근거	가중치 (%)
1년차 (2019)	AI 활용 실제 교량 거동 예측 가능성 실험적 증명	거동 예측 알고리즘 (실험)	실험적 증명 및 성능평가 단계, TRL 3·4	모델의 정확도 (오차율) 10% 이하	실측값과 비교	25
				교량 하중 시나리오 구성 타당성 95%	도로교 설계기준	
				AI 학습 정확도 (결함이 없는 교량) 90%	상관계수 확인	
				거동 예측 정확도 (오차율) 10% 이하	실측값과 비교	
	프로그램 개발	GUI 프로그램		인공지능연계 SW 1건	NIPA,SW자산뱅크 등록 확인	8
				시각화 SW 1건	NIPA,SW자산뱅크 등록 확인	
통합모니터링 SW 1건			NIPA,SW자산뱅크 등록 확인			
2년차 (2020)	건전성 평가 알고리즘 개발	결함 예측 알고리즘 (건전성평가)	유사환경 시험 및 기술시범 단계, TRL 5·6	결함 반영된 수치 모델의 정확도 (오차율) 10%이하	문헌 조사	25
				결함 시나리오 구성 타당성 95%	문헌 조사	
				AI 학습 정확도 (결함 있는 교량) 90%	상관계수 확인	
				결함 예측 정확도	수치 모델과 비교	
	프로그램 개발	GUI 프로그램		인공지능연계 SW 1건	NIPA,SW자산뱅크 등록 확인	8
3년차 (2021)	개발된 알고리즘의 기술시범	통합 시스템 개발	유사환경 기술시범 및 실제 환경 시작품 데모 단계, TRL 6·7	통합 알고리즘 정확도 90%	수치 해석, 문헌 조사	25
				건전성 평가 정확도 90%	수치 해석, 문헌 조사	
				실제 또는 유사 실험과 비교 90%	실험 수행, 문헌 조사	
				현장 활용 가능성 90%	실험 수행, 문헌 조사	
	프로그램 개발	GUI 프로그램		시각화 SW 1건	NIPA,SW자산뱅크 등록 확인	9

2. 연구개발과제의 수행 과정 및 수행 내용

2-1 연구개발 추진 전략 및 방법

1) 전문가 및 연구원 확보

- 연구 제안자는 토목 구조 해석 전공자로서, 토목 구조물의 수치해석 및 거동 분석에는 전문가이지만 인공지능분야에서는 전문성이 다소 미흡한 점이 있음. 제안자는 수년전부터 기업 및 연구기관과 무수히 많은 협력 연구를 진행해온 경험자로서, 제안한 연구에서도 다양한 분야의 전문가와의 협력 연구가 원활히 진행될 수 있을 것으로 기대한다. 특히 현재 국내 전문가로는 연구자가 소속되어 있는 컴퓨터공학과 및 전기전자공학과와 AI 연구자와 의견을 나누고 있음.
- 국외 전문가로는 세계최고 AI 전문가인 Stanford University 공과대학교 AI 연구실 또는 이 연구실 출신으로 현재 AI기반의 자율주행자동차 Drive.ai의 5명 창립자 중 한 명을 활용하여 AI의 전반적인 적용성과 최신기술에 대한 자문을 꾸준히 받고 있음.
- 또한, 동적 응답을 바탕으로 구조물의 손상과 위치에 대하여 다년간 연구해온 전문가를 활용하여 예측된 거동을 바탕으로 결함 예측 및 건전도 평가 알고리즘에 대한 자문을 받았음.

2) 실험을 통한 성능시험 검증

- 제안연구에서는 제안연구자에 의해 이미 이론적·기술적으로 정립되고 실내 실험등을 통하여 검증된 인공 지능을 활용한 구조물의 거동의 예측 기술을 실제 거더교량에 적용하여 성능을 시험함.
- 1차년도 상반기에 한국도로 공사에서 관리하고 있는 고속도로교량(경간 30m, 폭 13m PSC I형 1등급 거더 교량)에 대하여 해당기관의 협조를 얻어 실험을 수행하였음.


3) 정확한 수치해석을 통한 신뢰할 수 있는 데이터 획득

- 인공지능이 데이터를 예측하기 위해서는 학습 과정이 선행되어야 함. 이때, 관심있는 데이터를 포함하여(교량 전체 거동, 결함 정보 등) 학습에 필요한 데이터는 예측이 어려운 데이터이기 때문에 실측데이터를 얻는데 어려움이 있을 수 있음. 따라서, 이런 경우에 한해 제안 연구에서는, 검증된 정확한 수치모델의 시뮬레이션을 통하여 실측데이터를 대체하였음.
- 데이터의 신뢰성 확보를 위하여 학습 데이터를 수치 모델에서 획득하기 전에, 연구 대상교량에 실제 정적·동적 차량 하중을 재하하여 예측된 변형률, 변위 등을 수치 해석결과와 비교하여 수치모델을 검증하였고, 데이터의 신뢰성을 확보할 수 있었음.
- 정확한 수치모델은 수많은 예측 데이터를 얻기 위하여 필요한 비용, 시간 등을 대체할 수 있는 다양한 장점이 있기 때문에, 정확한 수치해석은 본 연구에서 매우 중요한 부분을 담당함.
- 연구 제안자는 다년간의 수치해석 경험이 있는 구조해석전문가로서, 실측데이터와 매우 유사한 수치해석이 가능함. 따라서, 정적·동적 하중에 대하여 정확한 수치해석이 수행된다면 실측데이터를 대체할 수 있음.

4) 인공지능을 활용한 거동 분석 및 건전성 평가 기술 개발

- 인공지능을 활용하면 실시간으로 구조물의 거동 분석 및 구조물의 건전성을 판단할 수 있음. 예를 들어, 특정 위치에 평상시보다 큰 처짐이 발생할 경우에는 해당위치에 과대한 하중이 가해졌거나 결함 발생 가능성 등을 예상할 수 있음. 따라서, 본 연구에서는 구조물의 노후화로 인한 강도 감소, local & global 결함 등을 고려하여 구조물의 건전성을 좀 더 분석적으로 평가할 수 있는 기술을 개발함.
- 결함의 유무, 종류, 위치, 크기 정도 등을 판단하여 구조물의 건전성을 실시간으로 파악할 수 있는 통합 알고리즘을 개발함. 이를 활용하면 예측데이터로부터 구조물의 거동을 파악할 수 있고, 구조물의 결함 등 실시간으로 건전성을 파악할 수 있음.

2-2 연구개발 추진체계



2-3 연구개발 추진일정

1차년도															
일련 번호	연구내용	추진 일정												연구 개발비 (단위: 천원)	책임자 (소속 기관)
		1	2	3	4	5	6	7	8	9	10	11	12		
1	수치해석 수행 및 인공지능 학습														연세 대학교
2	교량 시험 준비 및 실시														연세 대학교
3	GUI 프로그램 개발														에이팩스 소프트
4	프로그램에 시험 결과 적용														연세 대학교
5	알고리즘 수정 및 보완														연세 대학교

2차년도														
1	인공지능에 다양한 계층값 및 예측값 적용													연세 대학교
2	결함 예측 방법 문헌 조사 (전문가 활용)													연세 대학교
3	결함 시나리오 작성 및 수치해석													연세 대학교
4	건전성 평가 알고리즘 개발													연세 대학교
5	프로그램에 건전성 평가 알고리즘 탑재													에이펙스 소프트

3차년도														
1	구조물 건전도 평가 문헌 조사													연세 대학교
2	건전도 평가 알고리즘 개발													연세 대학교
3	최종 프로그램 개발													에이펙스 소프트
4	실제 교량에 성능 시험													연세 대학교
5	시험 결과 정리 및 프로그램 수정 보완													연세 대학교

2-4 연구개발 수행 과정 및 내용

1) 개발 AI 기술에 적용된 알고리즘

- 본 연구과제를 통해 최적 위치에서 측정된 변형률로부터 변위, 변위로부터 손상 상태 예측 알고리즘을 개발함.
- 개발 AI 기술에 적용된 기본 알고리즘은 artificial neural network(ANN)이고, 계층 지점 개수 및 위치 최적화는 genetic algorithm(GA)이다.
- 두 알고리즘을 기본으로 교량 변위 및 손상 상태 예측 알고리즘을 개발함.

(1) Artificial Neural Network (ANN)

- 인간 두뇌와 신경세포의 작동 메커니즘에서 영감을 얻어 만들어진 학습 및 의사결정 방법론인 ANN은 기계 학습의 범용 알고리즘으로 각광 받고 있음.
- ANN은 생물학적 신경망의 수학적 모델로, 생물학적 신경망을 아래 그림과 같이 다층 완전 연결 신경망으로 모사하였음.
- ANN은 입력 계층, 여러 은닉 계층 및 출력 계층으로 구성되어 있음.
- 한 계층의 모든 노드는 다음 계층의 다른 모든 노드에 연결되며, 숨겨진 레이어의 수를 늘려서 네트워크를 더 깊게 만들 수 있음.




그림 1. ANN의 일반적인 구조 (Yoshua et al., 2015)

① 신경망 모델 구성 : 뉴런, 시냅스, 활성화 함수

- ANN에서 뉴런은 node이고, 그 뉴런들을 연결하는 시냅스는 edge임.
- 각각의 시냅스의 중요도가 다를 수 있으므로 edge마다 weight를 따로 정의하게 되며 아래 그림과 같은 형태로 네트워크가 구성됨.




그림 2. 네트워크 구성 (Yoshua et al., 2015)

- 보통 ANN은 directed graph로, 정보의 전파방향이 한 방향으로 고정되어있음.
- 이 경우 정보 전파방향이 'forward'로만 일어나기 때문에 feed-forward network라고 부르기도 함.
- 실제 뇌에서는 각기 다른 뉴런들이 활성화 되고, 그 결과가 다음 뉴런으로 전달되고 또 그 결과가 전달 되면서 최종 결정을 내리는 뉴런이 활성화 되는 방식에 따라 정보를 처리하게 됨.
- 이 방식을 수학적 모델로 바뀌서 생각해보면, 입력 데이터들에 대한 활성화 조건을 함수로 표현하는 것이 가능하며, 이를 활성화 함수라고 정의함.
- 가장 간단한 활성화 함수의 예시는 들어오는 모든 입력값을 더한 다음, threshold를 설정하여 이 값이 특정 값을 넘으면 활성, 그 값을 넘지 못하면 비활성 되도록 하는 함수임.
- 일반적으로 많이 사용되는 활성화 함수는 아래와 같음.

sigmoid function : $f(t) = \frac{1}{1 + e^{-t}}$

tanh function : $f(t) = \frac{e^t - e^{-t}}{e^t + e^{-t}}$

absolute function : $f(t) = \|t\|$

ReLU function : $f(t) = \max(0, t)$

② Back-propagation algorithm

- ANN에서 활성화 함수들은 비선형성을 보이고, 서로 층을 이루면서 복잡하게 얽혀있음.
- 따라서, ANN의 weight 최적화는 non-convex 최적화임.
- 이는 일반적인 경우에 ANN parameter의 글로벌 최적점을 찾는 것이 불가능하다는 것을 의미함.
- 따라서 gradient descent 방법을 사용하여 적당한 값까지 수렴시키는 방법을 사용하게 된다.
- ANN의 parameter를 업데이트하기 위해서는 back-propagation algorithm이라는 것을 주로 사용하는데, 이는 단순히 ANN에서 gradient descent를 chain rule을 사용하여 단순화시켰다고 볼 수 있음.
- 모든 최적화 문제는 target function이 정의되어야 풀 수 있음.
- ANN에서는 마지막 decision layer에서 우리가 실제로 원하는 타겟 출력값과 현재 네트워크가 생성한 예측 출력값과의 loss function을 계산하여 그 값을 최소화하는 방식을 취함.
- 일반적으로 많이 선택하는 loss에는 다음과 같은 함수들이 있음.
- 아래 함수들에서 d-차원의 타겟 출력값 t 를 $t=[t_1, \dots, t_d]$ 로, 예측 출력값 x 를 $x=[x_1, \dots, x_d]$ 로 정의함.

sum of squares loss : $\sum_{i=1}^d (x_i - t_i)^2$

softmax loss : $-\sum_{i=1}^d \left[t_i \log \left(\frac{e^{x_i}}{\sum_{j=1}^d e^{x_j}} \right) + (1 - t_i) \log \left(1 - \frac{e^{x_i}}{\sum_{j=1}^d e^{x_j}} \right) \right]$

cross entropy loss : $\sum_{i=1}^d [-t_i \log x_i - (1 - t_i) \log (1 - x_i)]$

hinge loss : $\max(0, 1 - t \cdot x)$

- 이렇게 loss function이 주어진다면, 결정된 loss function을 통해 parameter 들에 대한 gradient를 구한 다음 그 값들을 사용해 parameter를 업데이트하기만 하면 됨.
- 하지만, 일반적인 경우에 대해 이와 같은 계산 과정이 쉽지 않음.
- Back-propagation algorithm은 chain rule을 사용해 gradient 계산을 엄청 간단하게 만들어주는 알고리즘으로, 각각의 parameter의 gradient를 계산할 때 parallelization도 용이하고, 알고리즘 디자인만 조금 잘하면 메모리도 많이 아낄 수 있기 때문에 실제 신경망 업데이트는 이 back-propagation 알고리즘을 사용하게 됨.
- Gradient descent method를 사용하기 위해서는 현재 parameter에 대한 gradient를 계산해야 하지만, 네트워크가 복잡해지면 그 값을 바로 계산하는 것이 엄청나게 어려워짐.
- 그 대신 back-propagation algorithm에서는 먼저 현재 parameter를 사용하여 loss를 계산하고, 각각의 parameter 들이 해당 loss에 대해 얼마만큼의 영향을 미쳤는지 chain rule을 사용하여 계산하고, 그 값으로 업데이트를 하는 방법임.
- 따라서 back-propagation algorithm은 크게 두 가지 페이즈로 나눌 수가 있는데, 하나는 전파 페이즈이며, 하나는 weight 업데이트 페이즈임.
- 전파 페이즈에서는 training input pattern에서부터 에러, 혹은 각 뉴런들의 변화량을 계산하며, weight 업데이트 페이즈에서는 앞에서 계산한 값을 사용해 weight를 업데이트 시킴.

○ 페이지 1: 전파

1. Forward propagation: 입력 훈련 데이터로부터 output을 계산하고, 각 출력 뉴런에서의 에러를 계산함. (입력층 -> 숨겨진 층 -> 출력층으로 정보가 흘러가므로 'forward' propagation이라 함.)
2. Back propagation: 출력 뉴런에서 계산된 에러를 각 edge들의 weight를 사용해 바로 이전 층의 뉴런들이 얼마나 에러에 영향을 미쳤는지 계산함. (출력층 -> 숨겨진 층으로 정보가 흘러가므로 'back' propagation이라 함.)

○ 페이지 2: weight 업데이트

1. Chain rule을 사용해 parameter 들의 gradient를 계산함.

- 이때, chain rule을 사용한다는 의미는 아래 그림에서 나타내는 것처럼, 앞에서 계산된 gradient를 사용해 지금 gradient 값을 업데이트한다는 의미임.




그림 3. Weight 업데이트 과정 (Yoshua et al., 2015)

- 위의 그림은 모두 $\partial z / \partial x$ 를 구하는 것이 목적인데, 직접 그 값을 계산하는 대신, y 층에서 이미 계산한 derivative인 $\partial z / \partial y$ 와 y 층과 x 에만 관계있는 $\partial y / \partial x$ 를 사용하여 원하는 값을 계산함.
- 만약 x 아래에 x' 이라는 parameter가 또 있다면, $\partial z / \partial x$ 와 $\partial x / \partial x'$ 을 사용하여 $\partial z / \partial x'$ 을 계산할 수 있음.
- 그러므로 back-propagation algorithm에서 필요한 것은 지금 업데이트하려는 parameter의 바로 전 변수의 derivative와 지금 parameter로 바로 전 변수를 미분한 값 두 개임.
- 이 과정을 출력층에서부터 하나하나 내려오면서 반복됨. 즉, 출력층 -> 숨겨진 k 번째 층, 숨겨진 k 번째 층 -> 숨겨진 $k-1$ 번째 층, ... 숨겨진 2번째 층 -> 숨겨진 1번째 층, 숨겨진 1번째 층 -> 입력층의 과정을 거치면서 계속 weight가 업데이트되는 것임.
- 이 과정을 맨 위에서 아래까지 반복하면 전체 gradient를 구할 수 있고, 이 gradient를 사용해 parameter 들을 업데이트할 수 있음.
- 이렇게 한 번의 iteration이 진행되고, 충분히 수렴했다고 판단될 때까지 이런 iteration을 계속 반복하는 것이 back-propagation algorithm이 parameter를 업데이트하는 방법임.




그림 4. Back-propagation 알고리즘의 process (Yoshua et al., 2015)

- 이렇듯 back-propagation은 weight를 바로 직접 변화시키는 것이 아니라 오직 에러만을 보고 gradient descent method을 통해 접근해 에러를 최소화하는 방향으로 계속 weight를 업데이트시킴.
- 또한, 한 번 에러가 연산된 이후에는 출력층에서부터 그 이전 층으로 '역으로' 정보가 업데이트되기 때문에 이를 back-propagation이라고 한다.

(2) Genetic Algorithm (GA)

- GA는 1970년대(1975년) 홀랜드가 개발한 확률적 방법을 사용하는 최적화 알고리즘임.
- GA는 자연 선택에 의한 생물학적 종의 진화 과정을 모방하였음.
- 다시 말해 생물의 진화와 유사하게 강한 종(체력 점수가 높은 종)은 다음 세대로 진화하는 반면 약한 종(체력 점수가 낮은 종)은 그 세대에서 사라짐.
- GA는 문제에 대한 다양한 가능한 해결책을 나타내는 부모 염색체의 무작위 모집단(숫자 벡터)에서 시작함.
- 부모 염색체(숫자 벡터) 내의 개별 구성 요소를 유전자라고 함.
- 각 숫자 벡터의 적합성은 목적 함수를 통해 측정됨.
- 피트니스 점수가 높은 일부 숫자 벡터는 직접 다음 세대로 이동하는 반면, 피트니스 점수가 낮은 숫자 벡터는 해당 세대에서 사라짐.
- GA는 사라진 솔루션을 대체할 수 있는 새로운 가능한 솔루션을 만드는 데 도움이 됨.
- 새로운 가능한 솔루션은 교차 및 돌연변이를 통해 생성됨.
- 교차는 두 개의 상위 숫자 벡터를 무작위로 선택하고 세그먼트를 서로 교환하는 데 도움이 되는 주요 연산자임.
- 다른 하나는 연산자가 기존의 숫자 벡터의 유전자를 임의의 유전자로 바꾸기 위해 사용되는 돌연변이임.
- 새로운 세대에서 생성된 숫자 벡터의 적합성은 목적 함수를 통해 다시 한번 측정됨.
- GA는 문제에 대한 최적의 숫자 벡터(즉, 가장 높은 적합성 점수를 가진)를 찾을 때까지 이 과정을 반복함.




그림 5. GA의 최적화 과정 (Moon et al., 2020)

(3) ANN과 GA를 활용한 변위 예측 과정

- 첫 단계로, 수치 모델(step 1)을 사용하여 변형률 측정 지점의 위치를 최적화함.
- 이 단계는 적은 수의 변형률에서 효율적으로 변위를 예측하기 위해 필요함.
- 측정 위치를 결정한 후, 훈련(set 1) 및 시험(set 2)에 필요한 변형 및 변위를 구조물(step 2)에서 측정함.
- ANN은 구축된 교육 데이터 (set 1)(step 3)를 사용하여 학습됨.
- 변형률과 변위는 각각 ANN의 입력과 출력 변수로 사용됨.
- 마지막으로, 훈련된 ANN 테스트의 경우 세트 2의 측정된 균주가 훈련된 ANN(step 4)에 입력됨.
- 그다음 ANN에서 예측한 변위를 Set 2의 측정된 변위와 비교함.
- 이와 같이 제안된 방법을 통해 교량, 건물 등 구조물의 변위를 빠르고 쉽게 예측할 수 있음.
- 훈련 데이터(set 1)는 단기 실험으로 측정하거나 수치 시뮬레이션을 통해 얻을 수 있음.




그림 6. ANN을 사용한 교량 변위 예측 과정 (Moon et al., 2020)

(4) 계측 지점 개수 및 위치 최적화 방법

- ANN은 변형률(= 입력)과 변위(= 출력) 사이의 관계를 훈련하기 때문에 입력으로 사용되는 변형률 측정 지점의 수와 위치는 훈련 결과에 상당한 영향을 미침.
- 일반적으로 입력으로 사용되는 균주의 수가 많을수록 변위 예측 정확도가 높아짐.
- 또한 센서 기술의 발전으로 구조에 많은 수의 센서를 설치할 수 있게 되었음.
- 그러나 이로 인해 설치 비용, 데이터 획득 및 분석 등과 같은 일부 경제적 문제가 발생할 수 있음.
- 또한 같은 수의 균주를 사용하더라도 균주의 위치에 따라 변위 예측 정확도가 크게 달라짐.
- 현장에서 센서 설치의 수와 위치는 직관 또는 경험적 지식에 의해 결정되기도 함.
- 그러나 이는 측정된 데이터의 유용성을 감소시켜 경제적, 시간적 손실을 초래함.
- 센서의 수와 위치가 데이터 이용에 큰 영향을 미치기 때문에 계측 지점 수와 위치 최적화에 대한 상당히 많은 연구가 수행되었음.

- 이러한 연구에서 GA, particle swarm 등과 같은 많은 지능형 알고리즘이 최적화에 활용되었음.
- 본 연구과제에서는 변형률과 변위를 측정하기 전에 유전자 알고리즘을 사용하여 변형률 측정 지점의 수와 위치를 최적화하는 방법을 개발함.
- 개발 방법은 수치 모델 데이터를 활용하여 수행됨.
- 다양한 하중 시나리오에서의 수치 시뮬레이션으로부터 구조물의 전체 변형률 및 변위를 구함.
- 수와 위치를 동시에 최적화하면 계산 시간이 효율적이지 않기 때문에 사전에 숫자를 선정하여 변형률 측정점 위치를 GA의 최적화 변수로 사용함.
- 먼저 변형률 측정점 개수(n_s)를 선택함.
- 그다음 GA는 n_s 변형률 측정 지점의 위치를 최적화 변수로 최적화하기 시작함.
- 그런 다음 훈련된 ANN의 MSE가 목적 함수로 사용됨. 입력으로 GA에 의해 생성된 위치에서 n_s 변형률을 사용하고 출력으로 전체 변위를 사용하여 ANN을 훈련 시킴.
- 그런 다음 GA는 각 세대의 모든 모집단(=적합도)에 대한 적합성 값을 평가함.
- 선택, 교차 및 돌연변이를 사용하여 GA는 적합성 값을 계속 평가함.
- GA는 최소 MSE, 최대 반복 등과 같은 정지 기준이 충족될 때까지 위 작업을 계속 반복함.
- 정지 기준을 만족한 후, 변형률 측정 지점의 최적(최적) 위치를 결정한다.




그림 7. ANN과 GA를 활용한 변형률 측정 지점 개수 및 위치 최적화 과정 (Moon et al., 2020)

2) 실험교량 현장 실험 전 변위 예측 가능성 확인

(1) 수치해석 모델을 이용한 변위 예측 가능성 확인

- 대상 구조물 실험 전 간단한 수치해석 모델을 이용하여 ANN을 이용한 변위 예측 가능성을 확인함.
- I형 거더교량에 차량하중을 재하하여, 동적 변형률로부터 동적 변위를 실시간 예측할 수 있는지 확인함.
- 최적화 위치를 결정하여, 2개 또는 3개의 변형률로부터 거더 전체의 변위 형상을 예측할 수 있음을 확인함.

표 1. 해석에 사용된 교량 정보

교량 형식	I-형 거더교(5 girders)
경간 개수	1 (단순지지)
경간 길이	36 m
슬래브 너비	15 m
차선 개수	4 (왕복 2차선)
재료	콘크리트(슬래브), 강(거더)




그림 8. 해석에 사용된 교량 모델 제원 (Moon et al., 2020)




그림 9. 수치해석 모델 (Moon et al., 2019)

표 2. 학습 및 검증에 사용된 차량 하중 시나리오

	Training Data (Set 1)			Test Data (Set 2)		
차량 속도 (km/h)	40	60	80	40	60	80
하중 시나리오 개수	24	24	24	1	1	1
시나리오당 데이터셋 개수	800	800	800	800	800	800
총 데이터셋 개수	57,600			2,400		




그림 10. 학습에 사용된 차량 하중 시나리오 예시 (Moon et al., 2019)




그림 11. 거더 하부 데이터 획득 위치(거더 당 11지점) (Moon et al., 2020)

표 3. 변형률 계측 위치(최적화 vs 임의의 위치)와 ANN 학습 결과

변형률 계측 지점 개수 (= n_s)		변형률 측정 지점 위치 (m)				학습 결과	
		Point 1	Point 2	Point 3	Point 4	MSE ($\times 10^{-3}$)	R
11		0~36 (3.6m 간격)				1.2007	0.9988
임의의 위치	4	7.2	14.4	25.2	28.8	5.4946	0.9947
	3	7.2	25.2	32.4	—	31.1106	0.9696
	2	14.4	21.6	—	—	44.0195	0.9575
최적화 위치	4	7.2	14.4	21.6	32.4	1.4268	0.9986
	3	7.2	18	25.2	—	1.7511	0.9983
	2	10.8	21.6	—	—	2.5370	0.9975







그림 12. 최적화된 변형률 계측 위치 (Moon et al., 2020)




(a) 임의위치에서의 변형률 값



(b) 최적화 위치에서의 변형률 값




(a) 임의위치에서의 변형률 값




(b) 최적화 위치에서의 변형률 값

그림 14. 60km/h 인 경우 시간에 따른 변위 예측 결과(최적화 vs 임의위치) (Moon et al., 2020)



(a) 임의위치에서의 변형을 값



(b) 최적화 위치에서의 변형을 값

그림 15. 80km/h 인 경우 시간에 따른 변위 예측 결과(최적화 vs 임의위치) (Moon et al., 2020)

(2) 실내 실험을 통한 예측 가능성 확인

- 캔틸레버빔을 이용하여, 현장 실험 전 실내 실험을 진행함.
- 캔틸레버빔 자유진동 시 발생하는 변형률과 변위를 계측함.
- 변형률을 입력 변수, 변위를 출력 변수로 설정하여 ANN 학습을 수행함.
- 캔틸레버빔에 하중을 가한 이후 자유진동 시 발생하는 실시간 변위 예측 결과를 확인함.
- 최적화된 위치인 경우, 변위 예측 정확도가 매우 높음을 확인함.
- 실내 실험을 이용한 검증 결과로부터, 현장 실험 적용 가능성 확인함.






그림 16. 실내 실험에 사용된 캔틸레버빔과 센서 설치(1,020mm)

표 4. 계측 위치(최적화 vs 임의의 위치)와 ANN training 및 test 결과

변형률 계측 지점 개수 (= n_s)		변형률 측정 지점 위치 (mm)			Training (Set 1)		Test (Set 2)
		Point 1	Point 2	Point 3	MSE	R	MSE
임의의 위치	3	400	600	700	1.6368	0.9727	0.9283
	2	600	700	—	4.8805	0.9161	4.1361
최적화 위치	3	100	600	700	1.5120	0.9748	0.3620
	2	100	700	—	1.5728	0.9737	0.3287




(a) S1 지점에서의 변형률 ($x = 100 \text{ mm}$)




(b) D3 지점에서의 변위 ($x = 1020 \text{ mm}$)

그림 17. 초기변위 10mm의 자유진동에 대한 계측 데이터 그래프(자유단) (Moon et al., 2020)




(a) D3 지점에서의 변위 ($x=1020$ mm)




(b) a 구간 확대

그림 18. 3개 변형률에 대한 자유단의 변위 예측 결과 (Moon et al., 2020)



(a) D3 지점에서의 변위 ($x=1020$ mm)



(b) a 구간 확대

그림 19. 2개 변형률에 대한 자유단의 변위 예측 결과 (Moon et al., 2020)

3) 연구 및 실험 대상으로 하는 거더 교량 수치해석

- 1차년도에는 실제 교량 실험을 진행하여, 연구팀이 기존에 개발한 인공 신경망을 이용한 변형률로부터 변위 예측 방법을 실험적으로 검증해 봄.
- 실험 대상 교량은 강원도 망상시에 위치한 망상3교로서, 5개의 거더로 이루어진 단경간 30m의 2차선의 교량임.
- 동일한 교량이 상행선과 하행선으로 건설되어있는데, 본 연구에서는 상행 2차선의 교량에 대하여 실험을 수행함.
- 교량 실험에 앞서, 수치해석을 통하여 해당 교량의 변위 예측 가능성을 확인함.
- 또한, 수치모델을 통해 센서(변형률, 변위, 가속도)의 위치를 결정(최적화)함.
- 수치모델의 정확도를 검증하기 위하여 다음의 두 가지 방법을 사용함.

(1) 이론값-해석값 비교

- 그림 20은 상용프로그램 아바쿠스를 이용하여 만든 교량 모델임.
- 망상 3교의 도면을 바탕으로 거더의 변단면을 실제로 표현하였고, 상부의 슬래브와 거더가 일체 거동을 하도록 모델을 생성함.
- 해당 모델의 검증을 위하여 교량 상부 중앙지점에 1000kN의 하중을 가하여 해석 처짐과 이론 처짐값을 비교해 봄.
- 이때, 오일러-빔 이론을 바탕으로 얻어진 처짐 공식($v = \frac{-wx}{24EI}(x^3 - 2Lx^2 + L^3)$)을 이용하였는데, 해당 공식의 I(단면 2차 모멘트)에는 변단면을 고려할 수 없기 때문에, 거더 중앙부 단면의 I값(단면 2차모멘트)을 기준으로 이론값을 계산함.
- 이론에 의한 거더 중앙부 처짐은 4.96mm로 계산되었고, 해석값은 거더 중앙부 처짐이 5.38mm로 오차가 8.4%(((5.38 - 4.96)/4.96)*100 = 8.4%)로 계산되었음.
- 해당 오차의 원인으로는 I값의 차이 때문인 것으로 판단됨. 즉, 실제 교량의 거더는 변단면이지만, 이론값에는 거더 중앙의 I 값을 사용하였기 때문인 것으로 판단됨.
- 거더 중앙부는 단면이 두껍기 때문에, 실제보다 I값이 더 크게 계산되어 결과적으로 해석에 의한 처짐보다 더 작은 처짐이 발생한 것으로 판단됨.
- 이론값과의 비교 결과를 그림 21에서 확인할 수 있음.




그림 20. 모델링 형상 (Moon et al., 2020)





그림 21. 이론값-해석값 비교

(2) 재하 실험값-해석값 비교


- 추가적인 검증을 위해 기존에 한국도로공사에서 시행한 재하실험 결과와 해석값을 비교해 봄.
- 그림 22는 재하시험에 사용된 차량의 제원을 보여주고 있다. 망상3교는 고속도로 교량의 일부로서 차량을 통제하는데 어려움이 있다. 따라서, 차량을 갓길에 정적 재하하여, 통행량이 없는 시점에 처짐을 계측 하였음.
- 차량 재하 위치는 그림 23에 나타나 있으며, 거더 5개 각각의 중앙부 처짐을 계측하였음.




구 분		재하차량 중량(tonf)
총중량		31.09
전륜	전륜1	8.69
	전륜2	7.94
후륜	후륜1	7.54
	후륜2	6.92

(b) 차량 중량

그림 22. 재하실험 차량 제원




(a) 재하 위치 (횡방향)




(b) 재하 위치 (종방향)

그림 23. 재하실험 차량 재하 위치

- 개발한 수치 모델은 콘크리트만을 고려하였고, 실제 교량 거더의 철근과 Post-tensioning 효과가 고려되지 않음.
- 이에 따라 수치 모델이 실제 교량보다 더 작은 강성을 가지고 있어서 차량 하중에 대한 처짐값이 $\text{처짐}_{\text{해석}} > \text{처짐}_{\text{실험}}$ 이 됨(그림 24(a)).
- 따라서, 절대적인 처짐값보다는, 해석값에 보정계수를 적용하여 실제 실험값과 해석값의 경향성이 일치하는지 비교하였음.
- 그림 24(b)에서 볼 수 있듯이 처짐비율을 보정계수로 사용하여 재하 실험값과 비교해 보았을 때, 10% 미만의 오차를 보임과 동시에 경향성이 실험결과와 매우 유사함을 확인할 수 있음.



(a) 거더별 처짐(실험값 vs 해석값)



(b) 거더별 처짐(실험값 vs 보정된 해석값)

그림 24. 거더별 중앙처짐 비교(실험값 vs 해석값)

- 검증된 수치모델을 이용하여 차량 하중을 재하한 후, 수치해석을 수행함.
- 사용한 차량 모델 및 제원은 도로설계기준의 KL-510을 기준으로 설정함(그림 25).
- 교량을 통과하는 차량의 종류는 매우 다양하지만, 이를 모두 표현하는 것이 쉽지 않기 때문에, 승용차·버스·트럭 3종류 차량으로 제한함.
- 차량 모델에 스프링 및 점성 감쇠기를 표현하여 차량과 교량 사이의 동적 효과를 표현함.
- 실제와 유사한 차량 분포를 표현하기 위하여 pearson type III 교통 이론 분포를 이용하여, 80, 100, 120km/h의 속도에 대하여 각각 10개(총 30개)의 하중 시나리오를 작성함(그림 26).
- 그림 27은 작성된 시나리오의 일부를 보여주고 있고, 그림 28은 이를 바탕으로 수치해석으로부터 얻어진 변형률과 변위 결과를 보여주고 있음.
- 실험 전 수행한 수치해석은 인공 신경망 적용 가능성과 부착 센서 위치를 결정하기 위한 데이터를 얻기 위하여 수행함.




그림 25. KL-510 하중(도로 설계 기준)




그림 26. Pearson type III 교통 분포 (Moon et al., 2019)






그림 27. 차량 하중 시나리오 예시 (Moon et al., 2019)



(a) 변형률



(b) 변위

그림 28. 수치해석 결과 (중앙 거더 중앙지점 / 80km/h)

4) 검증된 수치해석 결과 데이터를 이용한 거동 예측 AI 알고리즘 학습

(1) 수치해석 데이터를 이용한 학습 및 현장 실험 준비

- 수치모델에서 얻은 데이터(변형률, 변위)를 이용하여 인공 신경망에 학습해 보았을 때, 99% 이상의 높은 상관계수를 획득함.
- 수치해석 결과와 개발한 최적화 알고리즘(유전자 알고리즘)을 이용하여 실제 실험 현장에서의 센서 위치를 결정함.
- 공용 중인 고속도로 교량(망상3교)의 변형률 9지점, 변위 3지점, 가속도 3지점 계측함.
- 변형률의 경우 실험 전 해석 데이터를 이용하여 계측 지점을 최적화하였을 때, 2~3지점이면 충분히 변위를 예측할 수 있을 것으로 판단됨. 하지만, 최적 위치가 아닐 때의 예측 결과를 비교 및 다양한 위치의 실측 변형률 데이터를 활용해 보기 위하여 총 9지점에 변형률 센서 설치함.
- 바람의 영향을 최소화하기 위하여 바람막이용 천막을 사용함.
- 계측한 변형률, 변위를 이용하여 AI 학습 및 검증 수행함.




그림 29. 센서 설치 위치

표 5. 교량 정보

위치	강원도 동해시
경간 길이	30m
너비	12.275 m (two lanes)
거더 형식	PSC I (five girders)
콘크리트 강도	40 MPa
완공년도	2004



(a) 실험장소 위성사진



(b) 실험 대상 구조물 전경 사진

그림 30. 교량 위치 및 전경



그림 31. 교량 상부 차량 통행




그림 32. 교량 단면도



(a) 바람막이용 천막설치 1



(b) 바람막이용 천막설치 2



(c) 바람막이용 천막설치 3



(d) 바람막이용 천막설치 4



(e) 센서 설치 중




(f) 와이어 타입 변형률 게이지

그림 33. 실험 진행 현장 사진 1



(a) 거더 하단부 센서 설치 1



(b) 거더 하단부 센서 설치 2



(c) 천막 내부



(d) 천막 내부 링 변위계



(e) 동적 로거

그림 34. 실험 진행 현장 사진 2


(2) 해석 및 실험 데이터를 이용한 인공 신경망 학습

- 수치해석 데이터를 이용한 인공 신경망 학습 결과와 마찬가지로, 실제 계측한 데이터를 AI 학습시켰을 때도 역시, 90% 이상의 상관계수를 획득함. (R:상관계수)
- 앞서 언급하였던, 변형률 계측 위치에 따른 학습 및 검증 정확도를 비교해 봄.


표 6. 계측 위치에 따른 학습 및 검증 정확도 비교

구분	No. Strains	Location (m) [좌측기준]			상관계수
		Point 1	Point 2	Point 3	
Arbitrary	2	1.8	4.2	—	0.8749
	3	1.8	4.2	5.4	0.9066
Optimized	2	7.8	15	—	0.9991
	3	4.2	12.6	15	0.9995


- 최적화한 위치(연구를 통해 개발된 방법)의 변형률 데이터를 적용한 경우 높은 상관계수를 보여줌.




(a) 임의의 2 지점 변형률 이용



(b) 최적화된 2지점 변형률 이용



(c) 임의의 3 지점 변형률 이용



(d) 최적화된 3지점 변형률 이용

그림 35. 상관계수 결과

표 7. 학습 및 검증 데이터 구성

데이터		시간	데이터셋 개수
Training (Set 1)		09:00 - 11:00 (2시간)	1,440,000
Test (Set 2)	Set 2-1	12:00 - 12:04 (4분)	48,000
	Set 2-2	15:00 - 15:04 (4분)	48,000
	Set 2-3	18:00 - 18:04 (4분)	48,000




그림 36. 계측된 변위 (48시간)




그림 37. 계측된 변형률 데이터 처리 (거더 중앙 변형률)




그림 38. 계측된 변위 데이터 처리 (거더 중앙 변위)


표 8. ANN 학습에 사용된 변수

입력 노드 개수 (변형률)	2 또는 3
히든 노드 개수	3 - 3 or 2 - 2
출력 노드 개수 (변위)	3
Training 알고리즘	Scaled conjugate gradient
활성 함수	Tanh (hidden), linear (output)
Learning rate	0.01
Momentum	0.5
Epoch	500


5) 실제 교량에 하중 재하 실험 (학습된 AI 검증)

- 약 48시간에 걸쳐 변형률, 변위, 가속도 계측함.
- 이때, 동적하중(차량 등)에 의한 변형을 보기 위하여 sampling rate를 200Hz로 설정함.
- 학습된 AI에 학습에 사용되지 않은 변형률을 입력하였을 때, 예측한 변위와 실제 계측한 변위를 비교해 보았을 때, 평균 오차가 10% 이하로 계산됨.
- 평균 오차는 $\frac{(\text{계측 변위} - ANN\text{예측 변위})}{(\text{계측 변위})} \times 100 (\%)$ 의 전체 시간에 대한 평균값으로 계산함.
- 이때, 변위가 0인 지점을 제외한 모든 지점이 평균 오차를 계산하는데 포함됨.
- 전체적인 경향성은 매우 잘 예측하는 것으로 보이나, 온도효과·노이즈 효과 등 때문에 시간별로 정확도의 일관성이 약간 부족한 것으로 보임.
- 데이터 전처리를 통하여 온도효과와 noise effect를 제거한 후, 변위를 예측하였고 높은 정확도로 예측이 가능함을 확인함. (해당 결과를 활용하여 SCI 논문(2021년 online publihsed)게재 완료)

○ 변형률 3개 사용한 경우




(a) D3 지점의 변위




(b) a 구역 확대

그림 39. 3개 변형률에 대한 검증 결과(D3, Set 2-1) (Moon et al., 2020)




(a) D2 지점의 변위




(b) b 구역 확대

그림 40. 3개 변형률에 대한 검증 결과(D2, Set 2-1) (Moon et al., 2020)




(a) D1 지점의 변위




(b) c 구역 확대

그림 41. 3개 변형률에 대한 검증 결과(D1, Set 2-1) (Moon et al., 2020)




(a) D3 지점의 변위




(b) a 구역 확대

그림 42. 3개 변형률에 대한 검증 결과(D3, Set 2-2) (Moon et al., 2020)




(a) D2 지점의 변위




(b) b 구역 확대

그림 43. 3개 변형률에 대한 검증 결과(D2, Set 2-2) (Moon et al., 2020)




(a) D1 지점의 변위




(b) c 구역 확대

그림 44. 3개 변형률에 대한 검증 결과(D1, Set 2-2) (Moon et al., 2020)




(a) D3 지점의 변위




(b) a 구역 확대

그림 45. 3개 변형률에 대한 검증 결과(D3, Set 2-3) (Moon et al., 2020)




(a) D2 지점의 변위




(b) b 구역 확대

그림 46. 3개 변형률에 대한 검증 결과(D2, Set 2-3) (Moon et al., 2020)




(a) D1 지점의 변위




(b) c 구역 확대

그림 47. 3개 변형률에 대한 검증 결과(D1, Set 2-3) (Moon et al., 2020)

○ 변형률 2개 사용한 경우




(a) D3 지점의 변위




(b) a 구역 확대

그림 48. 2개 변형률에 대한 검증 결과(D3, Set 2-1) (Moon et al., 2020)




(a) D2 지점의 변위




(b) b 구역 확대

그림 49. 2개 변형률에 대한 검증 결과(D2, Set 2-1) (Moon et al., 2020)




(a) D1 지점의 변위




(b) c 구역 확대

그림 50. 2개 변형률에 대한 검증 결과(D1, Set 2-1) (Moon et al., 2020)




(a) D3 지점의 변위




(b) a 구역 확대

그림 51. 3개 변형률에 대한 검증 결과(D3, Set 2-2) (Moon et al., 2020)




(a) D2 지점의 변위




(b) b 구역 확대

그림 52. 2개 변형률에 대한 검증 결과(D2, Set 2-2) (Moon et al., 2020)




(a) D1 지점의 변위




(b) c 구역 확대

그림 53. 2개 변형률에 대한 검증 결과(D1, Set 2-2) (Moon et al., 2020)




(a) D3 지점의 변위




(b) a 구역 확대

그림 54. 2개 변형률에 대한 검증 결과(D3, Set 2-3) (Moon et al., 2020)




(a) D2 지점의 변위




(b) b 구역 확대

그림 55. 3개 변형률에 대한 검증 결과(D2, Set 2-3) (Moon et al., 2020)



(a) D1 지점의 변위



(b) c 구역 확대

그림 56. 2개 변형률에 대한 검증 결과(D1, Set 2-3) (Moon et al., 2020)

6) 실제 교량에 하중 재하 실험 결과 고찰

- ANN과 GA를 활용하여 최적 개수 및 위치에서의 센서 데이터를 통해 교량의 변위를 예측하는 알고리즘을 개발함.
- 수치해석 데이터 및 실내 실험을 통해 개발 알고리즘의 정확성을 평가하였고, 변위 예측의 정확성이 99% 이상임을 확인함.
- 실제 교량을 대상으로 하는 실험을 수행하기에 앞서 수치해석을 통해 실제 교량을 모델링하여 최적 센서 개수 및 위치를 선정하였고, 선정 결과를 바탕으로 실제 교량을 대상으로 실험을 수행함.
- 실제 교량으로부터 획득한 데이터를 개발 알고리즘에 적용하여 정확성 및 적용가능성을 평가함.
- 필터링 방법을 통해 획득한 데이터의 온도·노이즈 효과를 제거한다면, 변위 예측의 정확성이 99% 이상임을 확인함.
- 이를 통해 개발 알고리즘을 실제 교량에도 적용 가능함을 확인함.

7) 결함 반영된 거더 교량 수치해석

(1) 결함 반영된 수치 모델의 정확도

- 수치해석 수행시, 결함을 탄성 계수 감소, 또는 단면의 변화로 고려함.
- 연구에 사용된 캔틸레버빔의 임의의 구역의 탄성계수를 실제 대비 90%로 고려(10% 감소)하여 모멘트 면적법을 이용하여 이론적으로 자유단의 처짐을 계산함.
- 수치 모델에 탄성계수를 감소시켜 자유단의 처짐을 계산함.




그림 57. 해석에 사용된 캔틸레버빔

표 9. 해석결과와 이론식과의 비교

결함 위치	계산 결과 (이론식)	해석 결과 (수치모델)	백분율 오차
9번	31.76 mm	31.64 mm	0.39%

- 본 연구에서는 캔틸레버빔에 대해서 이론식을 이용하여 결함이 있는 경우, 처짐의 정확도를 검증함.
- 추후에 교량 모델을 검증할 때, 결함이 없는 경우에 이미 실제값과의 비교를 통하여 검증된 모델을 사용할 예정임.
- 일반적으로 교량의 거더는 빔과 같은 구조물이고, 동일한 방식(탄성계수 감소, 단면적 변화)으로 결함을 반영한 수치해석을 진행할 예정이기 때문에, 복잡한 모델에 대한 검증은 따로 필요하지 않을 것으로 판단됨.

(2) 해석을 위한 결함 시나리오 구성

- 결함에 관한 기존 연구에서 결함은 단면적 변화(부식) 또는 탄성계수의 변화(균열)을 주는 것이 일반적임.
- 이에 따라, 본 연구에서도 결함에 대하여 단면적 변화와 탄성 계수의 변화를 감소시켜 결함을 반영함.
- 고려한 대상 구조물(캔틸레버빔)의 모든 위치에 다양한 수준의 결함을 반영하여 수치해석을 수행함.




그림 58. 수치 모델에 사용된 캔틸레버빔

표 10. 결함 시나리오

결함 정도		결함 위치
탄성 계수	10% 감소	1구역 ~ 17구역
	20% 감소	1구역 ~ 17구역
	30% 감소	1구역 ~ 17구역
시나리오 개수(탄성 계수)		51개
단면 변화	10% 감소	1구역 ~ 17구역
	30% 감소	1구역 ~ 17구역
	50% 감소	1구역 ~ 17구역
시나리오 개수(단면 변화)		51개

8) 수치해석 결과 데이터를 이용한 결함 예측 AI 알고리즘 학습

(1) AI 학습 정확도

- 결함이 있는 캔틸레버빔에 자유진동에 대한 수치해석을 진행함.
- 총 17개 구역에 결함을 주었고, 결함은 탄성계수 감소와 단면적 감소를 고려함.
- 각각의 구역별로 350개의 데이터셋을 수치해석으로부터 얻었고, 총 17개 구역에 대하여 5,950(=17 × 350)개의 데이터셋을 획득함.
- 데이터셋은 변위형상(총 52개 노드)을 입력, 결함위치를 출력값으로 구성되어 있음.
- Pattern 인식 AI 알고리즘을 이용하여, 총 30만번의 iteration 후에 다음과 같은 훈련 결과 획득.

표 11. 학습 데이터셋 개수 및 결과

학습 데이터 개수	학습 / 검증 data ratio	학습 정확도
350 × 17구역 = 5,950 데이터셋	85/15	92.6 %




그림 59. 결함 위치 AI 알고리즘 학습 결과

- AI 학습 진행 시, 학습에 사용되는 데이터셋의 개수와 학습 결과를 실시간으로 확인하는 검증 데이터셋의 비율을 85:15로 하여 학습을 수행함.
- 은닉층은 2개로 하였고, 가장 큰 값이 출력되는 위치를 결함의 위치로 결정함.
- 총 30만번의 iteration을 수행하는데 약 10시간이 소요되었고, 병렬 연산을 이용하면 이 시간은 줄일 수 있을 것으로 기대됨.
- 1~15구역의 결함 위치는 95% 이상의 정확도로 예측이 되지만, 16, 17구역의 결함 위치는 정확도가 상대적으로 많이 떨어짐.
- 그럼에도 불구하고, 16, 17의 결함이 예측된 위치는 본래의 위치(16, 17) 주변으로 예측되었음.

- 이러한 결과는 학습 데이터 개수 증가, 신경망 iteration 증가, 은닉층 개수 변화 등으로 인하여 정확도를 향상시킬 수 있을 것으로 기대됨.
- 결과적으로 훈련 결과는 매우 높은 수준으로 예측됨.
- 유사한 훈련 결과가 결함의 정도를 예측할 때도 나옴.
- 훈련 결과가 유사하기 때문에, 결함의 정도에 대한 예측은 검증 결과에 기술함.

9) 학습된 AI 알고리즘 검증

(1) 결함 위치 예측 검증 결과

- 1차년도에 변형률로부터 변위 형상을 예측할 수 있음이 확인되었음. 다양한 결함을 고려한 수치 해석 데이터를 이용하여 1차년도에 개발한 변위 예측 알고리즘에 학습 및 검증을 진행하였고, 결함 존재 여부와 관계없이 변형률로부터 변위 형상을 예측할 수 있음이 확인됨.
- 2차년도에서 변위 형상으로부터 결함의 위치와 정도를 예측하는 AI 알고리즘을 개발하였음. 즉, 변위 형상을 입력으로 하고, 결함 위치를 출력으로 하여 AI 알고리즘을 학습하였다. 학습에 사용되지 않은 임의의 변위 형상을 입력하였을 때, AI가 결함 위치를 찾을 수 있는지 확인함.
- 각 구역별로, 22개의 데이터셋(입력 : 변위, 출력 : 결함 위치)을 검증해 봄.

예측 결함 위치	1	22	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100% 0.0%	
	2	0	22	0	0	0	0	0	0	0	0	0	0	0	0	0	100% 0.0%	
	3	0	0	22	0	0	0	0	0	0	0	0	0	0	0	0	100% 0.0%	
	4	0	0	0	22	0	0	0	0	0	0	0	0	0	0	0	100% 0.0%	
	5	0	0	0	0	22	0	0	0	0	0	0	0	0	0	0	100% 0.0%	
	6	0	0	0	0	0	22	0	0	0	0	0	0	0	0	0	100% 0.0%	
	7	0	0	0	0	0	0	22	0	0	0	0	0	0	0	0	100% 0.0%	
	8	0	0	0	0	0	0	0	22	0	0	0	0	0	0	0	100% 0.0%	
	9	0	0	0	0	0	0	0	0	21	0	0	0	0	0	0	100% 0.0%	
	10	0	0	0	0	0	0	0	0	0	22	0	0	0	0	0	100% 0.0%	
	11	0	0	0	0	0	0	0	0	0	0	22	0	0	0	0	100% 0.0%	
	12	0	0	0	0	0	0	0	0	1	0	0	21	0	0	0	95.5% 4.5%	
	13	0	0	0	0	0	0	0	0	0	0	0	1	22	1	0	91.7% 8.3%	
	14	0	0	0	0	0	0	0	0	0	0	0	0	0	21	0	100% 0.0%	
	15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	21	100% 0.0%	
	16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	16	72.7% 27.3%
	17	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6	17
	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	95.5% 4.5%	100% 0.0%	100% 0.0%	95.5% 4.5%	100% 0.0%	95.5% 4.5%	95.5% 4.5%	72.7% 27.3%	77.3% 22.7%	96.0% 4.0%
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	
	실제 결함 위치																	

그림 60. 결함 위치 검증 결과

표 12. 결함 위치 예측 정확도

결함 위치	1	2	3	4	5	6	7	8	9
예측 (예측/실제)	22/22	22/22	22/22	22/22	22/22	22/22	22/22	22/22	21/22
예측 정확도	100%	100%	100%	100%	100%	100%	100%	100%	95.5%
결함 위치	10	11	12	13	14	15	16	17	합계
예측 (예측/실제)	22/22	22/22	21/22	22/22	21/22	21/22	16/22	17/22	359/ 374
예측 정확도	100%	100%	95.5%	100%	95.5%	95.5%	72.7%	77.3%	96%

- 결함 시나리오를 작성한대로, 1,020mm의 캔틸레버빔을 17구역으로 나누어, 자유진동으로부터 변위 형상 데이터를 수치해석으로부터 획득함.
- 변위 형상 데이터와 결함 위치를 이용하여 AI 알고리즘 학습을 수행하였고, 임의의 변위 형상을 입력하였을 때, 결함 위치를 평균 96% 이상으로 예측할 수 있음이 확인됨.
- 결함 위치 예측 검증으로부터, 변위 형상으로부터 결함의 위치를 정확하게 예측할 수 있음이 확인됨.

(2) 결함 정도 예측 검증 결과

- 결함 위치 파악 후, 변위 형상으로부터 결함 정도를 예측하는 패턴인식 AI 알고리즘을 개발하였음.
- 결함의 정도는 탄성계수의 감소 정도를 index로 표현함.




표 13. 결함 정보 index

Index	결함 정보
1	탄성계수 10% 감소
2	탄성계수 20% 감소
3	탄성계수 30% 감소

그림 61. 결함 정보 검증 결과

표 14. 결함 예측 정확도

실제 결함 index	1	2	3	합 계
예측 개수 (예측 / 실제)	217 / 222	216 / 222	218 / 222	651 / 666
예측 정확도	97.7 %	97.3 %	98.2 %	97.7 %

- 탄성 계수의 감소를 결함으로 하여 결함의 정도를 예측해 보았을 때, 고려한 모든 결함에 대하여 평균 97.7%의 정확도를 보여주었다. 탄성 계수뿐만 아니라, 단면의 변화에 대해서도 유사한 정확도를 보여줌으로써, 개발한 AI 알고리즘을 이용하여 결함을 예측할 수 있음이 확인.

10) 최종 프로그램 및 알고리즘을 구조물에 적용

(1) 대상 구조물

- 1차년도 실험 대상 구조물인 망상3교에 개발한 통합 알고리즘을 적용함.
- 확보한 측정데이터로 교량 상태 예측 가능성을 확인함.
- 그림10에 표시된 A1, A2, 그리고 A3 위치에서의 측정데이터를 활용함.

(2) 데이터셋 구성

- 확보한 망상3교 24시간 측정데이터를 시간별로 나누어 분류함.
- 실제 망상3교 손상 상태 분석은 불가능함.
- 따라서, 시간이 지남에 따라 손상이 누적되어 손상 상태가 다르다고 가정함.
- 시간별로 나눈 데이터에 임의의 손상 상태를 부여함.

표 15. 시간별 데이터의 손상 상태 분류

결함 상태	1		2		3	
데이터 측정 시간	2019.09.25. 00:00~08:00		2019.09.25. 08:00~16:00		2019.09.25. 16:00~24:00	
데이터 분배	70%	30%	70%	30%	70%	30%
	학습용	시험용	학습용	시험용	학습용	시험용

(3) 대상 구조물에 알고리즘 적용 결과

- 위에서 구성된 데이터셋을 개발 알고리즘에 적용함.
- 실제 망상3교 손상 상태 분석은 불가능하기 때문에 결과 검증은 불가능함.
- 실제 교량 데이터를 적용하여 결과를 얻음으로써 개발 알고리즘의 실교량 적용 가능성을 확인함.




그림 62. 손상 상태 분류 결과

- 임의의 교량 데이터의 손상 상태 예측이 가능함을 확인함.
- 대상 구조물의 손상 상태가 같은 상태인 경우의 데이터를 임의로 나누었기 때문에 예측 결과의 정확도는 떨어짐.
- 대상 구조물의 현재 손상 상태 분석 완료 후 개발 알고리즘을 적용할 경우 높은 예측 정확도를 보일 것으로 기대함.

(4) 수치해석 데이터를 이용한 대상 구조물 손상 위치 및 정도 예측

- 손상 정도 및 위치 예측 알고리즘 검증을 위해 수치해석적 데이터를 사용함.
- 손상이 반영된 (탄성계수 및 단면적 감소) 캔틸레버빔에 대해 수치해석적 방법을 통해 총 5,950개의 데이터셋을 획득함.
- 손상 정도 및 위치 예측 알고리즘 검증 결과 96~97.7%의 정확도로 예측 가능함을 확인함.
- 수치해석적 데이터를 통해 검증된 손상 정도 및 위치 예측 알고리즘에 실제 교량에서 획득한 데이터를 적용하여 실제 현장에서의 적용 가능성을 확인함.
- 개발 알고리즘에 실제 교량 데이터를 적용할 시 손상 상태를 예측해 줌을 확인함.
- 실제 교량에 대한 손상 상태 조사가 이뤄질 시 높은 정확도로 손상 상태 예측이 가능할 것임을 확인함.

11) 제안된 실시간 구조물 건전도 정량화 기법 고도화

- 고려된 ANN 기법은 교량의 손상 정도 및 위치 파악에 있어 높은 예측 정확도를 확보하기 위해 긴 학습 시간이 필요함.
- 예측된 손상 정보의 실시간 업데이트를 위해선 보다 빠른 데이터 처리가 가능한 알고리즘 적용이 필요함.
- 이를 해결하기 위한 방안으로 데이터 처리에 있어 높은 처리 속도와 정확도를 보유한 tree-based 알고리즘을 개발함.
- 제안한 tree-based 알고리즘의 정확도 검증에 있어 기존 손상 분류에 널리 적용되는 알고리즘들도 함께 교차 검증함 (총 8개의 AI 알고리즘 고려).
- 계측된 손상 데이터를 활용하여 개발된 AI 알고리즘 학습을 수행하였고, 손상 정도 및 개수 예측 정확도를 파악하였음.

(1) AI 알고리즘 업데이트

- 다양한 데이터 종류를 활용해 교량의 손상 상태를 예측하기 위하여 AI 알고리즘을 사용하여 알고리즘 업그레이드 작업을 수행함.
- 개발한 머신러닝 알고리즘은 K-Nearest Neighbor(KNN), Naive Bayes, Decision Tree(DT), Random Forest(RF), Adaptive Boosting(AdaBoost), eXtreme Gradient Boosting(XGBoost), Light Gradient Boosting Machine(LightGBM), 그리고 Categorical Boosting(CatBoost)로 총 8개이며, 이중 tree-based 알고리즘은 총 6개임 (DT, RF, AdaBoost, XGBoost, LightGBM, 그리고 CatBoost).

① K-Nearest Neighbor (KNN)

- KNN은 비모수적이고 게으른 학습 알고리즘임.
- 비모수적이라는 것은 기본 데이터 분포에 대한 가정이 없음을 의미함.
- 즉, 데이터 집합에서 결정된 모델 구조임.
- 이 알고리즘에서는 입력 데이터가 형상 공간에서 가장 가까운 거리에 있는 K개의 데이터가 어떤 분류 값을 갖는지에 따라 입력 데이터를 분류함.
- 손상 상태 분류 값 c 에서 x 에 대한 조건부 확률은 다음과 같이 추정됨.

$$P_c(x) = \Pr(Y=c|X=x) = \frac{1}{K} \sum_{i \in N_K} I(y_i = c)$$

- 여기서 N_K 는 훈련 데이터에서 관측치에 가장 가까운 K개의 점 x 를 의미함.




그림 63. KNN 알고리즘 (Beyer et al., 1998)

② Naive Bayes

- Naive Bayes는 베이즈 정리에 기초한 통계 분류 기법임.
- 가장 간단한 지도 학습 알고리즘 중 하나임.
- Naive Bayes는 빠르고 정확하며 신뢰할 수 있는 알고리즘임.
- Naive Bayes 분류기는 대규모 데이터 세트에서 높은 정확도와 속도를 가지고 있음.
- Naive Bayes는 클래스의 특정 특징의 효과가 다른 특징들과는 독립적이라고 가정함.
- 이 가정은 계산을 단순화하며, 그것이 naive한 것으로 간주 되는 이유임.
- 이 가정을 계급 조건부 독립이라고 함.

$$P(h|D) = \frac{P(D|h)P(h)}{P(D)}$$

- $P(h)$: 가설 h 가 참일 확률(데이터에 관계 없이)이며, h 의 사전 확률임.
- $P(D)$: 가설에 관계없이 데이터의 확률임.
- $P(h|D)$: 데이터 D 가 주어졌을 때 가설 h 의 확률이며, 후방 확률이라 함.
- $P(D|h)$: 가설 h 가 참일 때 데이터 d 의 확률임.




그림 64. Naive Bayes 알고리즘 (Frank et al., 2006)

③ Decision Tree (DT)

- Decision tree는 ML 알고리즘 중 직관적으로 이해하기 쉬운 알고리즘임.
- 학습을 통해 데이터에 있는 규칙을 자동으로 찾아내 트리 기반의 분류 규칙을 만듦.
- 일반적으로 규칙을 가장 쉽게 표현하는 방법은 if/else 기반으로 나타내는 것임.
- 결정트리는 이와 같은 규칙이 적용되어 예측을 위한 규칙을 만드는 알고리즘임.
- 따라서 데이터의 어떤 기준을 바탕으로 규칙을 만들어야 가장 효율적인 분류가 될 것인가가 알고리즘의 성능을 크게 좌우함.
- 결정트리는 루트 노드, 규칙 노드, 그리고 리프 노드로 구성된다. 규칙 노드는 규칙 조건이 되는 것이고, 리프 노드는 결정된 분류 값이 됨.

- 새로운 규칙 조건마다 서브 트리가 생성되며 그에 따라 규칙 노드도 추가된다. 하지만 규칙이 많아질수록 분류 방식이 복잡해지게 되고, 이는 곧 과적합으로 이어지기 쉬움.
- 즉, 트리의 깊이가 깊어질수록 알고리즘의 예측 성능이 저하될 가능성이 높아짐.
- 가능한 한 적은 결정노드로 높은 예측 정확도를 가지려면 최대한 균일하게 데이터 세트를 구성해야 함.
- 이와 같은 데이터의 균일도를 측정하는 대표적인 방법으로 지니 계수임.
- 지니 계수는 0이 가장 평등하고 1로 갈수록 불평등함을 의미하지만, 머신러닝에 적용될 때 지니 계수는 값이 낮을수록 데이터의 균일도가 높음을 의미함.




그림 65. DT 알고리즘 (Breiman et al., 2017)

④ Random Forest (RF)

- 같은 알고리즘으로 여러 개의 분류기를 만들어서 보팅으로 최종 분류값을 결정하는 방식을 배깅이라 함.
- 이와 같은 배깅의 대표적인 알고리즘이 RF임.
- RF는 DT를 기반 알고리즘으로 함.
- 따라서, DT의 직관적인 장점을 그대로 가지고 있음.
- 또한, RF는 앙상블 알고리즘 중 비교적 빠른 수행 속도를 가지고 있으며, 다양한 영역에서 높은 예측 성능을 보이고 있음.
- RF는 여러 개의 DT가 전체 데이터에서 각자의 데이터를 샘플링해 개별적으로 학습을 수행한 뒤 최종적으로 모든 분류기가 보팅을 통해 예측 결정을 함.
- RF는 다음과 같이 네 가지 단계로 작동함.
 1. 여러 개의 DT가 전체 데이터셋에서 각자의 데이터를 랜덤하게 샘플링 함.
 2. 샘플링된 데이터에 대한 의사 결정 트리를 구성하고 각 의사 결정 트리에서 예측 결과를 얻음.
 3. 예측된 각 결과에 대해 투표를 수행함.
 4. 최종 예측으로 가장 많은 표를 얻은 예측 결과를 선택함.




그림 66. RF 알고리즘 (Breiman, L., 1996 & Breiman, L., 2001)

⑤ Boosting method

- 부스팅 방법은 약한 분류기 집합을 결합하여 모델의 성능을 향상시키는 방법임.
- 네 가지 부스팅 방법은 AdaBoost, XGBoost, LightGBM, 그리고 CatBoost 임.
- AdaBoost는 초기 스텝에서는 우선 모든 입력 변수에 대해 동일한 가중치를 부여함. 이후 잘못 분류된 관측지에 더 큰 비중의 가중치를 부여하여 모델을 재교육함. 따라서 이전 학습에 의한 결과를 가중치로 정리한 후 이를 바탕으로 모델을 교육함.
- XGBoost, LightGBM, 그리고 CatBoost 방법은 gradient boosting 방법의 일종임. 세 가지 방법 모두 의사결정 트리를 약한 분류기로 선택하고, gradient boosting을 사용하여 반복적으로 업데이트함.
- XGBoost는 이전 스텝에서 발생한 잔차(잘못 분류된 비율)를 반복적으로 업데이트함. 그러나 XGBoost는 입력 변수를 순차적으로 학습하기 때문에 학습 속도가 느림.
- LightGBM은 일반적인 GBM 계열과 다르게 leaf wise 방식을 이용함. 이 방식은 트리의 균형을 맞추지 않고 최대 잔차를 가지는 리프 노드를 지속적으로 분할하여 트리가 깊어지고 비대칭적인 트리를 만듦. 하지만 이러한 방식으로 트리를 계속해서 분할하게 되면 결국 균형 트리 분할 방식보다 예측 오류 손실을 최소화하게 됨.
- CatBoost는 입력 변수의 범주형 특징을 성공적으로 처리하는 모델임. 다른 부스팅 알고리즘과 한 가지 주요 차이점은 바로 CatBoost가 대칭 트리를 통해 알고리즘이 구현된다는 것임.
- 위 네 가지 부스팅 알고리즘에 대해 아래 간단한 그림67~68을 통해 조금 더 이해할 수 있음.

○ XGBoost




그림 67. eXtreme Gradient Boost (XGBoost) (Chen et al., 2016)

○ LightGBM




그림 68. LightGBM 구조 설명 (Ke et al., 2017)

○ CatBoost

시간	데이터 포인트	분류 번호
12:00	x1	10
12:01	x2	12
12:02	x3	9
12:03	x4	4
12:04	x5	52
12:05	x6	22
12:06	x7	32
12:07	x8	12
12:08	x9	27
1) x1의 잔차만 계산하고, 이를 기반으로 모델을 만들 2) 1)의 모델로 x2의 잔차를 예측 3) x1, x2의 잔차를 가지고 모델을 만들 4) 3)의 모델로 x3, x4의 잔차를 예측 5) x1, x2, x3, x4의 잔차를 가지고 모델을 만들 6) 5)의 모델로 x5, x6, x7, x8의 잔차를 예측 ⋮		

(2) 데이터셋 구성

① 실험을 통한 데이터 획득

- 실험 대상 구조물은 steel 빔 모형으로 총 두 종류의 손상 종류 (손상 개수 증가 vs 손상 정도 증가)에 대해 실험을 수행함.
- 서로 다른 두 개의 빔에 손상 개수와 정도를 증가해가며 실험을 수행함.
- 실험을 위한 빔의 기본 세팅은 그림 69, 70과 같음.
- 빔#1에는 손상 정도를 증가시키는 실험을 수행하기 위해 빔#1의 중앙에 길이 8cm의 손상을 깊이 1mm씩 증가시켜 총 6mm 깊이의 손상까지 실험을 수행함.
- 빔#2에는 손상 개수를 증가시키는 실험을 수행하기 위해 빔#2에 길이 8cm, 깊이 2mm 손상을 2개씩 증가시켜 총 10개의 손상까지 실험을 수행함.
- 빔에 가한 손상에 대한 정보는 그림 71, 72 에서 확인할 수 있음.
- 측정은 빔의 총 7점에서 가속도 및 변형률을 측정하였으며, 실험에 사용된 빔, 센서, 그리고 데이터 로거의 사양은 표 16과 같음.
- 하중은 빔 중앙에서 5cm 떨어진 지점에 1cm 변위하중을 가하였고, 각 실험마다 10회 반복하여 측정함.




그림 69. 실험 대상 구조물







그림 70. 대상 구조물 크기 및 하중 정보




(a) 손상 정보




(b) 실제 손상 사진

그림 71. 실내실험대상#1 손상 정보 (정도)



(a) 하단부



(b) 측면부



(c) 실제 손상 사진

그림 72. 실내실험대상#2 손상 정보 (개수)

- 실험에 사용된 데이터 로거 (그림 73 (a)), 모듈 (그림 73 (b), (c)) 및 센서 (그림 73 (d), (e))에 대한 정보는 아래 그림과 같으며, 해당 장비들의 스펙은 표 16과 같음.



(a) NI cDAQ-9178




(b) NI-9234



(c) NI-9237



(d) 가속도계



(e) 변형률계

그림 73. 사용 장비

표 16. 사용 장비 스펙

DAQ					
Model		Slot	Connectivity		Operating temp.
cDAQ-9178		4	USB 2.0		-20℃ - 55℃
모듈					
Model	Range	Channel	Sampling rate (/sec)	Resolution	Platform
NI-9234	±5V. Excitation-2mA	4	51.2K/ch	24bit	cDAQ/cRIO
NI-9237	Quarter-Bridge-120Ω & 350 Ω , Half, Full-Bridge-± 25mV/V, Excitation-2.5, 3.3, 5, 10V	4	50K/ch	-	cDAQ/cRIO
가속도계					
Model	Sensitivity (± 5%)	Measurement range	Frequency range (5%)	Operating temp.	
353B33	10.19mV/g	± 50g peak	1 - 4,000Hz	-54℃ - 121℃	
변형률계					
Model	Gauge pattern	Gauge factor	Gauge resistance	Operating temp.	
WFLA-3-350	2-wire system single element	2.07 ± 1%	350 ± 1.0Ω	0℃ - 80℃	


(3) 교량 손상 상태평가를 위한 고유진동수 산출 방법 개발

① 고유진동수 분석 결과


- 대상 구조물의 특정 구간의 단면적을 감소시켜 손상을 가함.
- 이는 아래와 같은 고유진동수 공식에서 질량(m) 값이 감소하였음을 의미함.
- 질량이 감소했음에도 대상 구조물의 고유진동수 값이 감소했다는 것은 손상 파악 지표인 강성(k)값이 손상으로 인한 질량 감소보다 더 크게 감소했다는 것을 의미함.

$$w_0 = \sqrt{\frac{k}{m}}$$

- 매번 측정마다 데이터 및 고유진동수를 확인함.
- 모든 손상 유형에서, 질량 감소에도 불구하고 고유진동수 값이 점차적으로 (monotonically) 감소함을 확인할 수 있었고, 이는 손상 증가에 의한 결과라 판단됨.
- 손상 정도가 반영된 고유진동수 변화 추이 및 절대값은 그림 74에 요약됨.



(a) 손상 정도 증가에 따른 결과




(b) 손상 개수 증가에 따른 결과


그림 74. 고유진동수 분석 결과

② 가속도로부터 계산된 변위 값 검증 결과


- 실제 현장에서 변위를 계측하기 위한 변위계 설치에 현장 특성상 가속도계 및 변형률계 설치에 비해 많은 시간이 소요되며 이는 계측의 정확도를 저해하는 요소로 작용함.
- 이를 해결하기 위한 방안으로 실험 진행 시 가속도계를 통해 측정된 가속도 데이터로부터 변위를 산출하는 기법을 적용함.
- 계산된 변위의 정확성을 확인하기 위해 실제 변위계를 사용하여 측정된 변위 데이터와 가속도계 사용을 통해 산출된 변위 데이터 값을 비교 분석함.
- 비교 결과, 절대 변위 값 및 고유진동수 값이 99% 이상 일치함을 확인함 (그림 75).
- 이를 통해 '가속도계를 통한 변위 산출' 방법의 정확도 및 활용성을 검증함.



(a) 측정 위치




변위값 비교




고유진동수 비교

(b) 1번 위치




변위값 비교




고유진동수 비교

(c) 2번 위치




변위값 비교




고유진동수 비교

(d) 3번 위치




변위값 비교




고유진동수 비교

(e) 4번 위치




변위값 비교




고유진동수 비교

(f) 5번 위치




변위값 비교




고유진동수 비교

(g) 6번 위치



변위값 비교




고유진동수 비교

(h) 7번 위치


그림 75. 실측 변위와 계산된 변위 비교 결과

③ 기존 ANN 알고리즘 모델을 활용한 계측 데이터 검증 (가속도 → 변위 산출)


- 1차년도때 개발한 변형률 - 변위 산출 ANN 알고리즘을 적용함.
- 실측 변위 값과 예측 변위 값의 FFT 분석결과, 모든 손상 유형에 대해서 산출된 고유진동수 값이 일치함을 확인함 (그림 76).
- 따라서, 변위 데이터는 가속도로부터 수학적으로 계산된 변위 값과 ANN 알고리즘을 통해 예측 변위 값 모두 높은 정확성을 지님을 확인하였고, 이를 통해 두 방법 모두 구조물 손상평가에 사용될 수 있음을 검증함.







(a) 측정 위치



변위값 비교




고유진동수 비교




상관계수 결과





(b) 1번 위치



변위값 비교




고유진동수 비교




상관계수 결과





(c) 2번 위치



변위값 비교




고유진동수 비교




상관계수 결과





(d) 3번 위치



변위값 비교




고유진동수 비교




상관계수 결과





(e) 4번 위치



변위값 비교




고유진동수 비교




상관계수 결과





(f) 5번 위치



변위값 비교




고유진동수 비교




상관계수 결과





(g) 6번 위치



변위값 비교



고유진동수 비교




상관계수 결과

(h) 7번 위치


그림 76. 실측 변위와 ANN 예측 변위 비교 결과

④ 수치해석을 통한 산출된 고유진동수의 정확성 검증


- 산출된 고유진동수의 정확성, 또한 이를 통한 구조물의 동특성 검증을 위해 수치해석 프로그램인 Abaqus (2018)를 활용하여 모드 분석 (modal analysis)을 수행함.
- 실험을 통해 얻은 각 손상 유형마다 빔의 고유진동수와 보드 분석을 통해 얻은 고유진동수 값을 비교함 (그림 77, 78, 표 17).
- 비교 결과 가속도계를 통해 산출한 고유진동수와 수치해석을 통해 계산된 고유진동수가 일치함을 확인함 (오차범위: 최대 1.3%, 최소 0.001%).
- 또한, 모드 분석을 통해 본 실험에서는 하중에 의해 빔 모형에서 pure bending이 지배적으로 발생함을 확인함.




(a) 실내실험대상#1 & #2 : 손상 없음




(b) 실내실험대상#1 : 1mm 손상




(c) 실내실험대상#1 : 2mm 손상




(d) 실내실험대상#1 : 3mm 손상




(e) 실내실험대상#1 : 4mm 손상



(f) 실내실험대상#1 : 5mm 손상




(g) 실내실험대상#1 : 6mm 손상




(h) 1차 모드 형상


그림 77. 모드 분석 결과 (실내실험대상 #1)




(a) 실내실험대상#2 : 2mm 손상 2개




(b) 실내실험대상#2 : 2mm 손상 4개




(c) 실내실험대상#2 : 2mm 손상 6개



(d) 실내실험대상#2 : 2mm 손상 8개



(e) 실내실험대상#2 : 2mm 손상 10개



(f) 1차 모드 형상

그림 78. 모드 분석 결과 (실내실험대상 #2)

표 17. 모드 분석 결과

빔 케이스 번호	고유진동수 (Hz)		오차 (%)
	실험값	모든 분석 결과 (1차 모드)	
1-0	5.6501	5.65	0.00177
1-1	5.5834	5.5906	0.12895
1-2	5.4858	5.4916	0.10573
1-3	5.2429	5.2601	0.32806
1-4	4.9429	4.9966	1.08641
1-5	4.5167	4.5682	1.14021
1-6	3.9001	3.8955	0.11795
2-2	5.4168	5.4113	0.10154
2-4	5.2501	5.2207	0.55999
2-6	4.9667	5.0267	1.20805
2-8	4.8501	4.8488	0.0268
2-10	4.7286	4.7927	1.35558

⑤ 고유진동수 변화를 통한 구조물 손상 평가의 적정성 확인

- 손상 증가에 따른 고유진동수 변화 추이, 계산된 변위와 예측된 변위의 사용 가능성, 그리고 수치해석용 상용프로그램을 사용한 모드 분석을 통해 실험 결과들을 검증함.
- 고유진동수 감소 현상은 질량 감소보다 강성(재료의 고유 물성치) 감소에 더 민감하다는 것을 검증하였고 이를 통해 본 연구에서 제안한 방법을 통해 산출한 고유진동수는 구조물 손상 정도를 평가할 수 있는 지표임을 확인하였음.
- 계측된 가속도 데이터를 통해 수학적으로 계산한 변위 데이터와 검증된 ANN 알고리즘을 통해 예측된 변위 데이터의 일치함을 확인함으로써 가속도계 측정을 통해 가속도 정보 구축뿐만 아니라, 정확한 변위 산출도 가능함을 검증하였음.
- 그러나 변위 형상 측면에서는, 학습된 변위보다 계산된 변위를 적용하는 것이 좀 더 높은 정확도를 확보할 수 있음을 확인함.
- 제안한 가속도→변위 산출 방법의 정확도를 수치해석을 활용한 모드 분석결과를 통해서도 검증하였음.
- 또한, 수치해석 결과를 통해 실험 대상 모형구조물의 동적 특성 (지배적인 pure bending) 역시 확인할 수 있음을 검증함.
- 위의 결론을 통해 본 연구에서 제안한 고유진동수 산출 방법의 정확성을 검증함. 또한, 이를 통해 고유진동수를 사용한 구조물 손상 평가의 적정성을 확인할 수 있었음.




그림 79. 교량 손상 상태 평가를 위한 고유진동수 적용의 적정성 확인

(4) 제안된 tree-based 알고리즘을 활용한 교량 손상 상태 평가

① Input과 output variables 구성

- 머신러닝 모델 개발에서 입력 변수의 선택은 예측 모델의 성능에 상당한 영향을 미침.
- 3차 년도의 대상 구조물인 빔 모형의 손상 상태 예측을 위해 본 연구에서는 변형률(S), 가속도(A), 변위(D) 그리고 고유진동수(F)를 변수(총 4개)로 설정함 (표 18).
- 위에서 고려된 각각의 변수의 다양한 조합으로 예측 정확성 및 오차를 확인함.
- 고려된 입력 변수의 조합은 AS, AD, ASD, ASF, ADF, ASDF 등 총 6개로 구성함 (표 18).
- 입력 변수인 변형률, 가속도 그리고 변위는 전체 데이터가 아닌 각 데이터의 피크 값(+, -)을 입력 변수로 적용함.
- 출력 변수는 교량의 손상 정도 및 개수를 고려한 총 12가지로 구성됨 (표 19).

표 18. 입력값 구성

변수		표기법	피크 개수
입력	가속도	A	10, 20, 30, 60, 90, 120, 150
	변형률	S	10, 20, 30, 60, 90, 120, 150
	변위	D	10, 20, 30, 60, 90, 120, 150
	고유진동수	F	-
입력 조합		AS, AD, ASD, ASF, ADF, ASDF	

표 19. 출력값 구성

변수		분류 번호	설명
출력	빔 #1 & 2	1-0	손상 없음
	빔 #1 손상 정도 증가	1-1	1mm 손상 (깊이)
		1-2	2mm 손상 (깊이)
		1-3	3mm 손상 (깊이)
		1-4	4mm 손상 (깊이)
		1-5	5mm 손상 (깊이)
		1-6	6mm 손상 (깊이)
	빔 #2 손상 개수 증가	2-2	손상 개수 2개
		2-4	손상 개수 4개
		2-6	손상 개수 6개
		2-8	손상 개수 8개
		2-10	손상 개수 10개

- 본 연구에서는 최적화된 빔 교량 손상 상태 평가를 위해 그림 80과 같이 실험을 통해 측정된 변형률, 가속도, 변위의 전체 측정데이터에서의 전체 피크 값 개수(B)와 입력 변수에 들어갈 피크 값 개수(a)의 비율을 조절하여 정확도 값을 비교함.
- 위의 방법은 입력 데이터의 용량을 줄임으로써 데이터 분석에 소요되는 시간을 단축시킬 수 있음과 동시에 가속도계에 계측된 다른 주파수 대역의 신호 (=noise)를 효율적으로 제거(filtering)할 수 있는 새로운 방법임.
- 또한, 그림 80에서 묘사된 바와 같이, a와 B의 비율 값이 예측 성능에 영향을 미치는 새로운 입력 변수로 설정되어 signal-to-noise ratio (SNR)를 향상시키고, 이를 통해 손상 예측 정확도를 향상시킬 수 있는 방법임.
- a/B 설정 기준에 대한 정보는 표 20을 통해 확인할 수 있음.
- 본 연구에서 머신러닝 알고리즘에 적용되는 데이터 포인트의 개수는 총 1,680개로 그림 81과 같이 구성됨.
- 총 1,680개의 데이터 포인트 수는 위에서 설명한 12가지의 손상 분류와 7점의 센서 위치, 그리고 각 각의 손상 유형에 대한 10회의 반복된 하중 재하를 고려해 획득한 데이터의 수임.




그림 80. a와 B의 의미

표 20. a/B값에 따른 피크 값 개수

a/B 비율	a/B < 1					a/B = 1	a/B > 1
피크 값 개수	10	20	30	60	90	120	150

Data point 1 빔 no damage 1번 센서 / 1회반복하중 - 가속도 peak값 (+) - 변형률 peak값 (+) - 변위 peak값 (+) - Frequency	Data point 2 빔 no damage 1번 센서 / 2회반복하중 - 가속도 peak값 (+) - 변형률 peak값 (+) - 변위 peak값 (+) - Frequency	...	Data point 840 빔#2 damage 10ea 7번 센서 / 10회반복하중 - 가속도 peak값 (+) - 변형률 peak값 (+) - 변위 peak값 (+) - Frequency
Data point 841 빔 no damage 1번 센서 / 1회반복하중 - 가속도 peak값 (-) - 변형률 peak값 (-) - 변위 peak값 (-) - Frequency	Data point 842 빔 no damage 1번 센서 / 2회반복하중 - 가속도 peak값 (-) - 변형률 peak값 (-) - 변위 peak값 (-) - Frequency	...	Data point 1680 빔#2 damage 10ea 7번 센서 / 10회반복하중 - 가속도 peak값 (-) - 변형률 peak값 (-) - 변위 peak값 (-) - Frequency

Data set

그림 81. 입력 변수 정보

② 제안한 tree-based 알고리즘 모델 적용 결과 및 분석

- 본 연구에서는 빔의 상태평가를 위해 8가지 머신러닝 모델을 적용함.
- 머신러닝 모델은 open-source python package Scikit-learn 0.24.1을 통해 개발하였으며, 전체 1,680개의 데이터 포인트를 모델에 적용함.
- 1,680개의 데이터 포인트 중 70%는 모델 학습에 사용하였고, 나머지 30%는 학습된 예측 모델의 정확도 평가를 위한 테스트에 사용함.
- 적용된 여러 예측 모델의 성능을 비교 및 평가하기 위해서 confusion matrix를 사용함.
- confusion matrix는 n차 제곱 행렬로 n은 출력 분류 번호 개수를 의미하는데, 본 연구에서는 출력 분류 번호가 총 12개이므로 n은 12임.
- confusion matrix의 대각선 요소들은 정확히 분류된 경우의 개수를 나타내며 이외의 요소들은 잘못 분류된 경우의 개수를 나타냄.
- 또한, confusion matrix를 통해 모델의 예측 정확도, precision, and recall을 확인할 수 있는데, 이는 다음 그림 82을 통해 확인할 수 있음.

	Predicted as positive	Predicted as negative	
Actual positive	True positive (TP)	False negative (FN)	$\text{Precision} = \frac{TP}{TP + FP}$
Actual negative	False positive (FP)	True negative (TN)	$\text{Recall} = \frac{TP}{TP + FN}$
			$\text{Accuracy} = \frac{TP + TN}{TP + FP + TN + FN}$

그림 82. Confusion matrix에서 precision, recall, accuracy의 의미

③ 고유진동수가 포함되지 않은 경우

○ Training 결과

- Training 결과를 confusion matrix를 통해 확인함 (그림 83).
- 모든 입력 조합에 대해 100%에 가까운 정확도를 보임을 확인함.
- 이는 입력데이터를 통해 알고리즘 학습이 제대로 수행되었음을 의미함.
- 특히, 분류번호 1번, 2번, 그리고 3번의 데이터는 거의 유사한 값을 가지고 있음에도 불구하고 완벽하게 분류하여 학습했음을 확인함.

		Predicted class												Recall
		1	2	3	4	5	6	7	8	9	10	11	12	
Actual class	1	100	0	0	0	0	0	0	0	0	0	0	0	1
	2	0	49	0	0	0	0	0	0	0	0	0	0	1
	3	0	0	99	0	0	0	0	0	0	0	0	0	1
	4	0	0	0	93	0	0	0	0	0	0	0	0	1
	5	0	0	0	0	102	0	0	0	0	0	0	0	1
	6	0	0	0	0	0	93	0	0	0	0	0	0	1
	7	0	0	0	0	0	0	88	0	0	0	0	0	1
	8	0	0	0	0	0	0	0	102	0	0	0	0	1
	9	0	0	0	0	0	0	0	0	107	0	0	0	1
	10	0	0	0	0	0	0	0	0	0	101	0	0	1
	11	0	0	0	0	0	0	0	0	0	0	99	0	1
	12	0	0	0	0	0	0	0	0	0	0	0	94	1
Precision		1	1	1	1	1	1	1	1	1	1	1	1	1

Accuracy

RF

		Predicted class												Recall
		1	2	3	4	5	6	7	8	9	10	11	12	
Actual class	1	101	0	0	0	0	0	0	0	0	0	0	0	1
	2	0	45	0	0	0	0	0	0	0	0	0	0	1
	3	0	0	106	0	0	0	0	0	0	0	0	0	1
	4	0	0	0	97	0	0	0	0	0	0	0	0	1
	5	0	0	0	0	100	0	0	0	0	0	0	0	1
	6	0	0	0	0	0	102	0	0	0	0	0	0	1
	7	0	0	0	0	0	0	82	0	0	0	0	0	1
	8	0	0	0	0	0	0	0	97	0	0	0	0	1
	9	0	0	0	0	0	0	0	0	97	0	0	0	1
	10	0	0	0	0	0	0	0	0	0	102	0	0	1
	11	0	0	0	0	0	0	0	0	0	0	98	0	1
	12	0	0	0	0	0	0	0	0	0	0	0	100	1
Precision		1	1	1	1	1	1	1	1	1	1	1	1	1

Accuracy

CatBoost

(a) 가속도 + 변형률 (AS)

		Predicted class												Recall
		1	2	3	4	5	6	7	8	9	10	11	12	
Actual class	1	106	0	0	0	0	0	0	0	0	0	0	0	1
	2	0	52	0	0	0	0	0	0	0	0	0	0	1
	3	0	0	96	0	0	0	0	0	0	0	0	0	1
	4	0	0	0	97	0	0	0	0	0	0	0	0	1
	5	0	0	0	0	101	0	0	0	0	0	0	0	1
	6	0	0	0	0	0	99	0	0	0	0	0	0	1
	7	0	0	0	0	0	0	95	0	0	0	0	0	1
	8	0	0	0	0	0	0	0	98	0	0	0	0	1
	9	0	0	0	0	0	0	0	0	97	0	0	0	1
	10	0	0	0	0	0	0	0	0	0	98	0	0	1
	11	0	0	0	0	0	0	0	0	0	0	95	0	1
	12	0	0	0	0	0	0	0	0	0	0	0	93	1
Precision		1	1	1	1	1	1	1	1	1	1	1	1	1

Accuracy

RF

		Predicted class												Recall
		1	2	3	4	5	6	7	8	9	10	11	12	
Actual class	1	101	0	0	0	0	0	0	0	0	0	0	0	1
	2	0	50	0	0	0	0	0	0	0	0	0	0	1
	3	0	0	89	0	0	0	0	0	0	0	0	0	1
	4	0	0	0	94	0	0	0	0	0	0	0	0	1
	5	0	0	0	0	102	0	0	0	0	0	0	0	1
	6	0	0	0	0	0	92	0	0	0	0	0	0	1
	7	0	0	0	0	0	0	98	0	0	0	0	0	1
	8	0	0	0	0	0	0	0	107	0	0	0	0	1
	9	0	0	0	0	0	0	0	0	101	0	0	0	1
	10	0	0	0	0	0	0	0	0	0	95	0	0	1
	11	0	0	0	0	0	0	0	0	0	0	103	0	1
	12	0	0	0	0	0	0	0	0	0	0	0	95	1
Precision		1	1	1	1	1	1	1	1	1	1	1	1	1

Accuracy

CatBoost

(b) 가속도 + 변위 (AD)

		Predicted class													
		1	2	3	4	5	6	7	8	9	10	11	12	Recall	
Actual class	1	102	0	0	0	0	0	0	0	0	0	0	0	1	
	2	0	52	0	0	0	0	0	0	0	0	0	0	1	
	3	0	0	95	0	0	0	0	0	0	0	0	0	1	
	4	0	0	0	93	0	0	0	0	0	0	0	0	1	
	5	0	0	0	0	97	0	0	0	0	0	0	0	1	
	6	0	0	0	0	0	91	0	0	0	0	0	0	1	
	7	0	0	0	0	0	0	94	0	0	0	0	0	1	
	8	0	0	0	0	0	0	0	107	0	0	0	0	1	
	9	0	0	0	0	0	0	0	0	99	0	0	0	1	
	10	0	0	0	0	0	0	0	0	0	96	0	0	1	
	11	0	0	0	0	0	0	0	0	0	0	100	0	1	
	12	0	0	0	0	0	0	0	0	0	0	0	101	1	
Precision		1	1	1	1	1	1	1	1	1	1	1	1	1	Accuracy

		Predicted class													
		1	2	3	4	5	6	7	8	9	10	11	12	Recall	
Actual class	1	97	0	0	0	0	0	0	0	0	0	0	0	1	
	2	0	51	0	0	0	0	0	0	0	0	0	0	1	
	3	0	0	92	0	0	0	0	0	0	0	0	0	1	
	4	0	0	0	104	0	0	0	0	0	0	0	0	1	
	5	0	0	0	0	93	0	0	0	0	0	0	0	1	
	6	0	0	0	0	0	91	0	0	0	0	0	0	1	
	7	0	0	0	0	0	0	94	0	0	0	0	0	1	
	8	0	0	0	0	0	0	0	103	0	0	0	0	1	
	9	0	0	0	0	0	0	0	0	92	0	0	0	1	
	10	0	0	0	0	0	0	0	0	0	104	0	0	1	
	11	0	0	0	0	0	0	0	0	0	0	97	0	1	
	12	0	0	0	0	0	0	0	0	0	0	0	109	1	
Precision		1	1	1	1	1	1	1	1	1	1	1	1	1	Accuracy


CatBoost

(c) 가속도 + 변형률 + 변위 (ASD)


그림 83. Confusion matrix 결과 (training)

○ 정확도 비교 결과


- 적용한 8가지 알고리즘 중 최소 60% 이상의 정확도를 보여주는 알고리즘에 대해 정확도 비교 분석을 수행함 (그림 84).
- 60% 이상의 정확도를 보이는 알고리즘은 RF, LightGBM, XGBoost, 그리고 CatBoost 모델임이 확인됨.
- 위 4가지 모델의 입력 변수 조합 및 a/B 비율에 따른 정확도를 그림 84와 같이 분석함.
- 입력 변수 조합이 가속도 + 변형률(AS)인 경우에는 a/B가 1보다 작은 경우 지속적인 증가 추세를 보임.
- 이후부터는 정확도 값 차이가 거의 변화가 없으며, 정확도가 가장 높은 경우는 a/B>1 일 때의 RF와 CatBoost 모델로 최대 94%의 정확도를 보임.
- 입력 변수 조합이 가속도 + 변위(AD)인 경우에는 a/B가 1보다 작은 경우 지속적인 증가 추세를 보임.
- 그러나, a/B=3/4~1 구간에서는 오히려 정확도가 떨어지고 이후 정확도가 소폭 상승하는 것을 확인할 수 있음.
- 정확도가 가장 높은 경우는 a/B=3/4 일 때의 CatBoost 모델로 최대 96%의 정확도를 보임.
- 입력 변수 조합이 가속도 + 변형률 + 변위(ASD)인 경우에는 a/B=1인 경우까지 지속적인 증가 추세를 보임.
- 이후엔 오히려 정확도가 떨어지는 것을 확인할 수 있으며, 정확도가 가장 높은 경우는 a/B=1일 때의 RF 모델로 최대 97%의 정확도를 보임.



(a) 가속도 + 변형률 (AS)



(b) 가속도 + 변위 (AD)



(c) 가속도 + 변형률 + 변위 (ASD)

그림 84. 입력 조합에 따른 정확도 비교 결과

○ Confusion matrix 결과 심층 분석

- 그림 85에 묘사된 바와 같이, 손상 상태에 대한 예측 결과가 그림 83에서 묘사된 훈련 결과보다 정확도가 감소하는 것을 확인할 수 있음.
- 출력 분류 번호 1(손상 없는 상태의 빔)과 2(빔#1 1mm 깊이의 손상)의 예측 정확도 값이 다른 분류 번호의 결과보다 낮음을 확인할 수 있음.
- 이는 2번 케이스의 손상이 빔의 거동에 큰 영향을 미치지 못해서 손상이 없는 경우인 1번 케이스의 거동과 큰 차이가 없기 때문이라고 판단됨.

- 또한, 출력 분류 번호 8(빔#2 2mm 깊이의 손상 2개)의 값이 다른 분류 번호의 결과보다 낮음을 확인할 수 있음.
- 이는 8번 케이스의 손상이 빔의 거동에 큰 영향을 미치지 못해서 손상이 없는 경우인 1번 케이스의 거동과 큰 차이가 없기 때문이라고 판단됨.

		Predicted class													
		1	2	3	4	5	6	7	8	9	10	11	12	Recall	
Actual class	1	32	4	0	0	0	0	0	0	1	2	0	0	0.8205	
	2	0	22	0	0	0	0	0	2	1	0	0	0	0.88	
	3	0	0	31	3	0	0	0	0	0	0	0	0	0.9118	
	4	1	0	0	39	1	0	0	0	0	0	0	2	0.907	
	5	0	0	0	0	38	0	0	0	0	0	0	2	0.95	
	6	0	0	0	0	0	38	0	0	0	0	0	0	1	
	7	0	0	0	0	0	0	58	0	0	0	0	0	1	
	8	3	0	0	0	0	0	0	39	0	1	0	0	0.907	
	9	0	0	0	0	0	0	0	2	39	2	0	0	0.907	
	10	0	0	0	0	0	0	0	0	1	37	0	0	0.9737	
	11	0	0	0	0	0	0	0	0	0	0	42	0	1	
	12	0	0	0	0	0	0	0	0	0	3	0	37	0.925	
Pre- cision		0.8889	0.8462	1	0.9286	0.9744	1	1	0.907	0.9286	0.8222	1	0.9024	0.9358	Accuracy

		Predicted class													
		1	2	3	4	5	6	7	8	9	10	11	12	Recall	
Actual class	1	36	3	0	0	0	0	0	0	0	0	0	0	0.9231	
	2	1	19	0	0	0	0	0	2	3	0	0	0	0.76	
	3	0	0	20	4	0	0	0	0	0	0	0	0	0.8824	
	4	0	0	1	40	1	0	0	0	0	0	0	1	0.9302	
	5	0	0	3	0	36	0	0	0	0	0	0	1	0.9	
	6	0	0	0	0	0	38	0	0	0	0	0	0	1	
	7	0	0	0	0	0	0	58	0	0	0	0	0	1	
	8	2	4	0	0	0	0	0	37	0	0	0	0	0.8605	
	9	0	0	0	0	0	0	0	1	41	1	0	0	0.9535	
	10	0	0	0	0	0	0	0	0	1	37	0	0	0.9737	
	11	0	0	0	0	0	0	0	0	0	0	42	0	1	
	12	0	0	0	1	0	0	0	0	0	1	0	38	0.95	
Pre- cision		0.9231	0.7308	0.8824	0.8889	0.973	1	1	0.925	0.9111	0.9487	1	0.95	0.9358	Accuracy

CatBoost

(a) 가속도 + 변형률 (AS)

		Predicted class													
		1	2	3	4	5	6	7	8	9	10	11	12	Recall	
Actual class	1	33	4	0	0	0	0	0	2	0	0	0	0	0.8462	
	2	1	19	0	0	0	0	0	0	0	0	0	0	0.95	
	3	1	0	50	0	0	0	0	0	0	0	0	0	0.9804	
	4	0	0	0	45	1	0	0	0	0	0	0	0	0.9783	
	5	0	0	0	0	37	0	0	0	0	1	0	0	0.9737	
	6	0	0	0	0	0	48	0	0	0	0	0	0	1	
	7	0	0	0	0	0	0	42	0	0	0	0	0	1	
	8	3	3	0	0	0	0	0	26	0	1	0	0	0.7879	
	9	1	0	0	0	0	0	0	0	38	0	0	0	0.9744	
	10	0	0	0	0	4	0	0	0	1	38	0	2	0.8444	
	11	0	0	0	0	0	0	0	0	0	0	37	0	1	
	12	0	0	0	0	0	0	0	0	0	0	0	45	1	
Pre-cision		0.8462	0.7308	1	1	0.881	1	1	0.9286	0.9744	0.95	1	0.9574	0.9482	Accuracy

RF

		Predicted class													
		1	2	3	4	5	6	7	8	9	10	11	12	Recall	
Actual class	1	34	2	0	0	0	0	0	3	0	0	0	0	0.8718	
	2	2	18	0	0	0	0	0	0	0	0	0	0	0.9	
	3	1	0	50	0	0	0	0	0	0	0	0	0	0.9804	
	4	0	0	1	45	0	0	0	0	0	0	0	0	0.9783	
	5	0	0	0	0	37	0	0	0	0	1	0	0	0.9737	
	6	0	0	0	0	0	48	0	0	0	0	0	0	1	
	7	0	0	0	0	0	0	42	0	0	0	0	0	1	
	8	2	1	0	0	0	0	0	30	0	0	0	0	0.9091	
	9	1	0	0	0	0	0	0	0	37	1	0	0	0.9487	
	10	0	0	0	0	2	0	0	0	0	43	0	0	0.9556	
	11	0	0	0	0	0	0	0	0	0	0	37	0	1	
	12	0	0	0	0	0	0	0	0	0	2	0	43	0.9556	
Pre-cision		0.85	0.8571	0.9804	1	0.9487	1	1	0.9091	1	0.9149	1	1	0.9607	Accuracy

CatBoost

(b) 가속도 + 변위 (AD)

		Predicted class													
		1	2	3	4	5	6	7	8	9	10	11	12	Recall	
Actual class	1	34	1	0	0	0	0	0	3	0	0	0	0	0.8947	
	2	1	17	0	0	0	0	0	0	0	0	0	0	0.9444	
	3	0	0	42	3	0	0	0	0	0	0	0	0	0.9333	
	4	0	0	0	46	1	0	0	0	0	0	0	0	0.9787	
	5	0	0	0	0	43	0	0	0	0	0	0	0	1	
	6	0	0	0	0	0	49	0	0	0	0	0	0	1	
	7	0	0	0	0	0	0	46	0	0	0	0	0	1	
	8	1	0	0	0	0	0	0	32	0	0	0	0	0.9697	
	9	0	1	0	0	0	0	0	0	40	0	0	0	0.9756	
	10	0	0	0	0	1	0	0	0	0	43	0	0	0.9773	
	11	0	0	0	0	0	0	0	0	0	0	40	0	1	
	12	0	0	0	0	0	0	0	0	0	1	0	38	0.9744	
Pre- cision		0.9444	0.8947	1	0.9388	0.9556	1	1	0.9143	1	0.9773	1	1	0.9731	Accuracy

RF

		Predicted class													
		1	2	3	4	5	6	7	8	9	10	11	12	Recall	
Actual class	1	38	2	0	0	0	0	0	2	0	0	0	0	0.9048	
	2	1	16	0	0	0	0	0	0	0	0	0	0	0.9412	
	3	0	0	51	4	0	0	0	0	0	0	0	0	0.9273	
	4	0	0	0	42	0	0	0	0	0	0	0	0	1	
	5	0	0	0	0	35	0	0	0	0	0	0	0	1	
	6	0	0	0	0	0	47	0	0	0	0	0	0	1	
	7	0	0	0	0	0	0	41	0	0	0	0	0	1	
	8	1	0	0	0	0	0	0	30	0	0	0	0	0.9677	
	9	0	1	0	0	0	0	0	1	43	0	0	0	0.9556	
	10	0	0	0	0	0	0	0	0	0	46	0	0	1	
	11	0	0	0	0	0	0	0	1	0	0	41	0	0.9762	
	12	0	0	0	0	0	0	0	0	0	2	0	38	0.95	
Pre- cision		0.95	0.8421	1	0.913	1	1	1	0.8824	1	0.9583	1	1	0.9689	Accuracy



CatBoost

(c) 가속도 + 변형률 + 변위 (ASD)



그림 85. Confusion matrix 결과 (test)

○ 입력 변수 중요도 분석


- 추가적으로 손상 상태 예측의 정확도를 향상시키기 위해 입력 변수 (A, S, D, F)의 중요도에 대한 분석을 실시함.
- 입력 변수의 중요도란 알고리즘에 분류 또는 예측 과정에서 여러 개의 입력 변수 중 어떤 입력 변수가 가장 중요한 변수로 정해졌는지에 대한 상대적인 지표임 (가장 높은 중요도의 경우: 1, 가장 낮은 중요도의 경우: 0).
- 입력 조합에서 최고의 성능을 보여준 머신러닝 알고리즘 모델 RF와 CatBoost 모델에 대해서만 입력 변수 중요도 분석을 수행함.
- 입력 변수 중요도 분석에 대한 결과는 그림 86에 요약함.
- RF와 CatBoost 모델 모두 초반부 또는 후반부 피크값이 중반부 피크값보다 예측성능에 더 큰 영향을 미치는 것을 확인할 수 있음.
- RF 모델 같은 경우는 입력 변수 조합에 변형률이 포함된 경우에(AS, ASD) 변형률 보다 변위가 더 중요한 입력 변수이고, 변형률과 변위보다 가속도가 더 중요한 입력 변수임이 확인됨.
- CatBoost 모델도 RF 모델과 같이 중요도가 가속도, 변위, 그리고 변형률 순서임을 확인함.




(a) 가속도 + 변형률 (AS)



(b) 가속도 + 변위 (AD)



RF



CatBoost

(c) 가속도 + 변형률 + 변위 (ASD)

그림 86. 입력 변수 중요도 분석 결과 (RF, CatBoost)

- 고유진동수가 포함되지 않은 경우에서의 교량 손상 및 건전성 평가
 - 고유진동수가 포함되지 않은 세 가지 입력 조합(AS, AD, ASD)에서는 RF와 CatBoost 모델이 가장 높은 정확도를 보였으며, 나머지 모델은 이 두 모델보다 성능이 현저히 떨어짐 (약 30~40% 이상의 오차)을 확인할 수 있었음.
 - 계측된 가속도, 변형률, 변위 데이터에서 입력 변수에 들어갈 피크 값 개수(a)와 전체 피크 값 개수(B)와의 비율 ($= a/B$)이 $3/4(=75\%)$ 인 경우의 입력 변수만 적용되어도 약 93.6%이상의 정확도를 확보할 수 있음을 확인함.
 - 더 높은 정확도를 확보하여야 할 경우, AS의 조합에서는 $a/B=1$ 에서 1보다 큰 값으로 단계적으로 높여 간다면 1% 이상의 정확도 향상을 기대할 수 있고, ASD 조합의 경우엔 $a/B=1$ 로 높이면 97% 수준의 정확도를 기대할 수 있음을 확인함.
 - 전체 결과 분석 결과, 입력 변수 조합에 고유진동수가 포함되지 않은 경우, tree-based 알고리즘 모델이 기존의 구조물 손상 평가를 위해 사용된 전통적인 머신러닝 알고리즘 보다 30~40% 이상의 높은 성능을 보임을 검증함.

④ 고유진동수가 포함된 경우

○ Training 결과

- Training 결과를 confusion matrix를 통해 확인함 (그림 87).
- 고유진동수가 포함되지 않은 경우와 마찬가지로 training 결과 모든 입력 조합에 대해 100%에 가까운 정확도를 보임을 확인함.
- 이는 입력데이터를 통해 알고리즘 학습이 제대로 수행되었음을 의미함.
- 특히, 분류번호 1번, 2번, 3번, 그리고 8번의 데이터는 거의 유사한 값을 가지고 있음에도 불구하고 완벽하게 분류하여 학습했음을 확인함.

		Predicted class												Recall
		1	2	3	4	5	6	7	8	9	10	11	12	
Actual class	1	94	0	0	0	0	0	0	0	0	0	0	0	1
	2	0	56	0	0	0	0	0	0	0	0	0	0	1
	3	0	0	83	0	0	0	0	0	0	0	0	0	1
	4	0	0	0	98	0	0	0	0	0	0	0	0	1
	5	0	0	0	0	97	0	0	0	0	0	0	0	1
	6	0	0	0	0	0	105	0	0	0	0	0	0	1
	7	0	0	0	0	0	0	97	0	0	0	0	0	1
	8	0	0	0	0	0	0	0	101	0	0	0	0	1
	9	0	0	0	0	0	0	0	0	94	0	0	0	1
	10	0	0	0	0	0	0	0	0	0	107	0	0	1
	11	0	0	0	0	0	0	0	0	0	0	100	0	1
	12	0	0	0	0	0	0	0	0	0	0	0	95	1
Precision		1	1	1	1	1	1	1	1	1	1	1	1	1

Accuracy

LightGBM

		Predicted class												Recall
		1	2	3	4	5	6	7	8	9	10	11	12	
Actual class	1	99	0	0	0	0	0	0	0	0	0	0	0	1
	2	0	51	0	0	0	0	0	0	0	0	0	0	1
	3	0	0	94	0	0	0	0	0	0	0	0	0	1
	4	0	0	0	95	0	0	0	0	0	0	0	0	1
	5	0	0	0	0	97	0	0	0	0	0	0	0	1
	6	0	0	0	0	0	101	0	0	0	0	0	0	1
	7	0	0	0	0	0	0	100	0	0	0	0	0	1
	8	0	0	0	0	0	0	0	92	0	0	0	0	1
	9	0	0	0	0	0	0	0	0	97	0	0	0	1
	10	0	0	0	0	0	0	0	0	0	105	0	0	1
	11	0	0	0	0	0	0	0	0	0	0	99	0	1
	12	0	0	0	0	0	0	0	0	0	0	0	97	1
Precision		1	1	1	1	1	1	1	1	1	1	1	1	1

Accuracy

CatBoost

(a) 가속도 + 변형률 + 고유진동수 (ASF)

		Predicted class													
		1	2	3	4	5	6	7	8	9	10	11	12	Recall	
Actual class	1	103	0	0	0	0	0	0	0	0	0	0	0	1	
	2	0	51	0	0	0	0	0	0	0	0	0	0	1	
	3	0	0	101	0	0	0	0	0	0	0	0	0	1	
	4	0	0	0	92	0	0	0	0	0	0	0	0	1	
	5	0	0	0	0	98	0	0	0	0	0	0	0	1	
	6	0	0	0	0	0	99	0	0	0	0	0	0	1	
	7	0	0	0	0	0	0	99	0	0	0	0	0	1	
	8	0	0	0	0	0	0	0	100	0	0	0	0	1	
	9	0	0	0	0	0	0	0	0	96	0	0	0	1	
	10	0	0	0	0	0	0	0	0	0	98	0	0	1	
	11	0	0	0	0	0	0	0	0	0	0	96	0	1	
	12	0	0	0	0	0	0	0	0	0	0	0	94	1	
Precision		1	1	1	1	1	1	1	1	1	1	1	1	1	Accuracy

LightGBM

		Predicted class													
		1	2	3	4	5	6	7	8	9	10	11	12	Recall	
Actual class	1	96	0	0	0	0	0	0	0	0	0	0	0	1	
	2	0	42	0	0	0	0	0	0	0	0	0	0	1	
	3	0	0	95	0	0	0	0	0	0	0	0	0	1	
	4	0	0	0	93	0	0	0	0	0	0	0	0	1	
	5	0	0	0	0	99	0	0	0	0	0	0	0	1	
	6	0	0	0	0	0	108	0	0	0	0	0	0	1	
	7	0	0	0	0	0	0	100	0	0	0	0	0	1	
	8	0	0	0	0	0	0	0	95	0	0	0	0	1	
	9	0	0	0	0	0	0	0	0	104	0	0	0	1	
	10	0	0	0	0	0	0	0	0	0	100	0	0	1	
	11	0	0	0	0	0	0	0	0	0	0	99	0	1	
	12	0	0	0	0	0	0	0	0	0	0	0	96	1	
Precision		1	1	1	1	1	1	1	1	1	1	1	1	1	Accuracy

CatBoost

(b) 가속도 + 변위 + 고유진동수 (ADF)

		Predicted class												Recall
		1	2	3	4	5	6	7	8	9	10	11	12	
Actual class	1	96	0	0	0	0	0	0	0	0	0	0	0	1
	2	0	42	0	0	0	0	0	0	0	0	0	0	1
	3	0	0	95	0	0	0	0	0	0	0	0	0	1
	4	0	0	0	93	0	0	0	0	0	0	0	0	1
	5	0	0	0	0	99	0	0	0	0	0	0	0	1
	6	0	0	0	0	0	108	0	0	0	0	0	0	1
	7	0	0	0	0	0	0	100	0	0	0	0	0	1
	8	0	0	0	0	0	0	0	95	0	0	0	0	1
	9	0	0	0	0	0	0	0	0	104	0	0	0	1
	10	0	0	0	0	0	0	0	0	0	100	0	0	1
	11	0	0	0	0	0	0	0	0	0	0	99	0	1
	12	0	0	0	0	0	0	0	0	0	0	0	96	1
Precision		1	1	1	1	1	1	1	1	1	1	1	1	1

Accuracy

LightGBM

		Predicted class												Recall
		1	2	3	4	5	6	7	8	9	10	11	12	
Actual class	1	97	0	0	0	0	0	0	0	0	0	0	0	1
	2	0	51	0	0	0	0	0	0	0	0	0	0	1
	3	0	0	92	0	0	0	0	0	0	0	0	0	1
	4	0	0	0	104	0	0	0	0	0	0	0	0	1
	5	0	0	0	0	93	0	0	0	0	0	0	0	1
	6	0	0	0	0	0	91	0	0	0	0	0	0	1
	7	0	0	0	0	0	0	94	0	0	0	0	0	1
	8	0	0	0	0	0	0	0	103	0	0	0	0	1
	9	0	0	0	0	0	0	0	0	92	0	0	0	1
	10	0	0	0	0	0	0	0	0	0	104	0	0	1
	11	0	0	0	0	0	0	0	0	0	0	97	0	1
	12	0	0	0	0	0	0	0	0	0	0	0	109	1
Precision		1	1	1	1	1	1	1	1	1	1	1	1	1

Accuracy


CatBoost

(c) 가속도 + 변형률 + 변위 + 고유진동수 (ASDF)


그림 87. Confusion matrix 결과 (training)

○ 정확도 결과


- 적용한 8가지 알고리즘 중 100%에 가까운 정확도를 보여주는 알고리즘에 대해 정확도 비교 분석을 수행함 (그림 88).
- DT, LightGBM, XGBoost, 그리고 CatBoost 알고리즘 모델의 경우 100%에 가까운 정확도를 보이는 것으로 검증됨.
- 위 4가지 모델의 입력 변수 조합 및 a/B 비율에 따른 정확도를 그림 87과 같이 분석함.
- 고유진동수가 포함되지 않은 경우와는 다르게 모든 경우에 대해서 피크 값 개수가 최소인 10개인 경우에도 100%에 가까운 정확도를 보임을 확인함.
- 이를 통해 빔 교량의 손상평가를 하는데 있어 고유진동수의 변화가 다른 변수 (가속도, 변형률, 변위)의 변화보다 강성 변화에 민감하게 반응한다는 것을 유추할 수 있음.
- 더 나아가 본 연구에서 제안한 고유진동수 산출 방법은 통합적인 구조물 손상 평가를 수행하는데 있어 높은 신뢰도를 지님을 확인함.



(a) 가속도 + 변형률 + 고유진동수 (ASF)



(b) 가속도 + 변위 + 고유진동수 (ADF)



(c) 가속도 + 변형률 + 변위 + 고유진동수 (ASDF)

그림 88. 입력 조합에 따른 정확도 비교 결과

○ Confusion matrix 결과 심층 분석

- Confusion matrix 분석 결과, 훈련 결과(그림 87)와 같이 100%의 정확도를 보임을 확인할 수 있음 (그림 89).
- 고유진동수가 포함되지 않는 경우에 분류 정확도가 떨어지던 1번, 2번, 3번, 그리고 8번 케이스에 대해서도 100%의 정확도로 분류함을 확인함.
- 손상 상태 예측 정확도와 마찬가지로, Confusion matrix 분석 결과에서도 고유진동수가 강성 변화에 가장 민감하게 반응한다는 것을 확인하였고, 이를 통해 빔 교량의 손상평가를 하는데 있어 고유진동수 변화를 모니터링하는 것이 가장 효율적인 방안인 것을 제안함.

		Predicted class													
		1	2	3	4	5	6	7	8	9	10	11	12	Recall	
Actual class	1	46	0	0	0	0	0	0	0	0	0	0	0	1	
	2	0	14	0	0	0	0	0	0	0	0	0	0	1	
	3	0	0	57	0	0	0	0	0	0	0	0	0	1	
	4	0	0	0	42	0	0	0	0	0	0	0	0	1	
	5	0	0	0	0	43	0	0	0	0	0	0	0	1	
	6	0	0	0	0	0	35	0	0	0	0	0	0	1	
	7	0	0	0	0	0	0	43	0	0	0	0	0	1	
	8	0	0	0	0	0	0	0	39	0	0	0	0	1	
	9	0	0	0	0	0	0	0	0	46	0	0	0	1	
	10	0	0	0	0	0	0	0	0	0	33	0	0	1	
	11	0	0	0	0	0	0	0	0	0	0	40	0	1	
	12	0	0	0	0	0	0	0	0	0	0	0	45	1	
Pre- cision		1	1	1	1	1	1	1	1	1	1	1	1	1	Accuracy

LightGBM

		Predicted class													
		1	2	3	4	5	6	7	8	9	10	11	12	Recall	
Actual class	1	41	0	0	0	0	0	0	0	0	0	0	0	1	
	2	0	19	0	0	0	0	0	0	0	0	0	0	1	
	3	0	0	46	0	0	0	0	0	0	0	0	0	1	
	4	0	0	0	45	0	0	0	0	0	0	0	0	1	
	5	0	0	0	0	43	0	0	0	0	0	0	0	1	
	6	0	0	0	0	0	39	0	0	0	0	0	0	1	
	7	0	0	0	0	0	0	40	0	0	0	0	0	1	
	8	0	0	0	0	0	0	0	48	0	0	0	0	1	
	9	0	0	0	0	0	0	0	0	43	0	0	0	1	
	10	0	0	0	0	0	0	0	0	0	35	0	0	1	
	11	0	0	0	0	0	0	0	0	0	0	41	0	1	
	12	0	0	0	0	0	0	0	0	0	0	0	43	1	
Pre- cision		1	1	1	1	1	1	1	1	1	1	1	1	1	Accuracy

CatBoost

(a) 가속도 + 변형률 + 고유진동수 (ASF)

		Predicted class													
		1	2	3	4	5	6	7	8	9	10	11	12	Recall	
Actual class	1	37	0	0	0	0	0	0	0	0	0	0	0	1	
	2	0	19	0	0	0	0	0	0	0	0	0	0	1	
	3	0	0	39	0	0	0	0	0	0	0	0	0	1	
	4	0	0	0	48	0	0	0	0	0	0	0	0	1	
	5	0	0	0	0	42	0	0	0	0	0	0	0	1	
	6	0	0	0	0	0	41	0	0	0	0	0	0	1	
	7	0	0	0	0	0	0	41	0	0	0	0	0	1	
	8	0	0	0	0	0	0	0	40	0	0	0	0	1	
	9	0	0	0	0	0	0	0	0	44	0	0	0	1	
	10	0	0	0	0	0	0	0	0	0	42	0	0	1	
	11	0	0	0	0	0	0	0	0	0	0	44	0	1	
	12	0	0	0	0	0	0	0	0	0	0	0	46	1	
Pre- cision		1	1	1	1	1	1	1	1	1	1	1	1	1	Accuracy

LightGBM

		Predicted class													
		1	2	3	4	5	6	7	8	9	10	11	12	Recall	
Actual class	1	44	0	0	0	0	0	0	0	0	0	0	0	1	
	2	0	28	0	0	0	0	0	0	0	0	0	0	1	
	3	0	0	45	0	0	0	0	0	0	0	0	0	1	
	4	0	0	0	47	0	0	0	0	0	0	0	0	1	
	5	0	0	0	0	41	0	0	0	0	0	0	0	1	
	6	0	0	0	0	0	32	0	0	0	0	0	0	1	
	7	0	0	0	0	0	0	40	0	0	0	0	0	1	
	8	0	0	0	0	0	0	0	45	0	0	0	0	1	
	9	0	0	0	0	0	0	0	0	36	0	0	0	1	
	10	0	0	0	0	0	0	0	0	0	40	0	0	1	
	11	0	0	0	0	0	0	0	0	0	0	41	0	1	
	12	0	0	0	0	0	0	0	0	0	0	0	44	1	
Pre- cision		1	1	1	1	1	1	1	1	1	1	1	1	1	Accuracy

CatBoost

(b) 가속도 + 변위 + 고유진동수 (ADF)

		Predicted class													
		1	2	3	4	5	6	7	8	9	10	11	12	Recall	
Actual class	1	44	0	0	0	0	0	0	0	0	0	0	0	1	
	2	0	28	0	0	0	0	0	0	0	0	0	0	1	
	3	0	0	45	0	0	0	0	0	0	0	0	0	1	
	4	0	0	0	47	0	0	0	0	0	0	0	0	1	
	5	0	0	0	0	41	0	0	0	0	0	0	0	1	
	6	0	0	0	0	0	32	0	0	0	0	0	0	1	
	7	0	0	0	0	0	0	40	0	0	0	0	0	1	
	8	0	0	0	0	0	0	0	45	0	0	0	0	1	
	9	0	0	0	0	0	0	0	0	36	0	0	0	1	
	10	0	0	0	0	0	0	0	0	0	40	0	0	1	
	11	0	0	0	0	0	0	0	0	0	0	41	0	1	
	12	0	0	0	0	0	0	0	0	0	0	0	44	1	
Pre- cision		1	1	1	1	1	1	1	1	1	1	1	1	1	Accuracy

LightGBM

		Predicted class													
		1	2	3	4	5	6	7	8	9	10	11	12	Recall	
Actual class	1	43	0	0	0	0	0	0	0	0	0	0	0	1	
	2	0	19	0	0	0	0	0	0	0	0	0	0	1	
	3	0	0	48	0	0	0	0	0	0	0	0	0	1	
	4	0	0	0	36	0	0	0	0	0	0	0	0	1	
	5	0	0	0	0	47	0	0	0	0	0	0	0	1	
	6	0	0	0	0	0	49	0	0	0	0	0	0	1	
	7	0	0	0	0	0	0	46	0	0	0	0	0	1	
	8	0	0	0	0	0	0	0	37	0	0	0	0	1	
	9	0	0	0	0	0	0	0	0	48	0	0	0	1	
	10	0	0	0	0	0	0	0	0	0	36	0	0	1	
	11	0	0	0	0	0	0	0	0	0	0	43	0	1	
	12	0	0	0	0	0	0	0	0	0	0	0	31	1	
Pre- cision		1	1	1	1	1	1	1	1	1	1	1	1	1	Accuracy


CatBoost

(c) 가속도 + 변형률 + 변위 + 고유진동수 (ASDF)


그림 89. Confusion matrix 결과 (test)

○ 입력 변수 중요도 결과

- 고유진동수가 포함된 입력 조합에서는 예측성능이 가장 좋은 DT, LightGBM, XGBoost, 그리고 CatBoost 모델에 대해서만 입력 변수 중요도를 분석함 (그림 90, 91).
- 그러나 그림 90과 같이 DT와 XGBoost 모델은 입력 변수 중 고유진동수의 영향이 지배적임. 따라서 이 두 알고리즘 모델을 사용하는 경우 손상 예측 성능에 한계가 있음을 확인함.
- LightGBM과 CatBoost 모델의 입력 변수 중요도 분석 결과, 가속도, 변형률, 그리고 변위 데이터의 초반부 피크값과 고유진동수 값이 예측성능에 큰 영향을 미치는 것을 확인할 수 있음 (그림 91).
- 특히, LightGBM 모델 같은 경우는 입력 변수 조합에 변형률이 포함된 경우에(ASF, ASDF) 변형률 보다 변위가 더 중요한 입력 변수이고, 변형률과 변위보다 가속도가 더 중요한 입력 변수임을 확인함.
- CatBoost 모델의 경우 LightGBM 모델과 마찬가지로 가속도, 변위, 그리고 변형률 순서로 정확도 예측에 영향을 미치는 것을 확인함.
- 특히, 입력 변수 조합이 가속도 + 변형률 + 변위 + 고유진동수(ASDF)인 경우 변형률과 변위는 예측성능에 거의 영향이 없음을 확인함.




DT




XGBoost

(a) 가속도 + 변형률 + 고유진동수 (ASF)




DT




XGBoost

(b) 가속도 + 변위 + 고유진동수 (ADF)





DT




XGBoost

(c) 가속도 + 변형률 + 변위 + 고유진동수 (ASDF)


그림 90. 입력 변수 중요도 분석 결과 (DT, XGBoost)



(a) 가속도 + 변형률 + 고유진동수 (ASF)




LightGBM




CatBoost

(b) 가속도 + 변위 + 고유진동수 (ADF)



LightGBM



CatBoost

(c) 가속도 + 변형률 + 변위 + 고유진동수 (ASDF)

그림 91. 입력 변수 중요도 분석 결과 (LightGBM, CatBoost)

○ 고유진동수가 포함된 경우에서의 교량 손상 및 건전성 평가

- 고유진동수가 포함된 세 가지 입력 조합(ASF, ADF, ASDF)에서는 DT, LightGBM, XGBoost, 그리고 CatBoost 모델이 100%에 가까운 정확도를 보였으며, 나머지 모델은 이 두 모델보다 성능이 떨어짐 (20% 이상의 오차)을 확인할 수 있음.
- 고유진동수가 포함된 입력 조합에서는 선정된 피크 값(a)/전체 피크 값(B)이 $1/12(a/B)$ 만 되어도 99.5% 이상의 정확도를 확보할 수 있음을 확인함.
- DT와 XGBoost 모델은 100%에 가까운 정확도를 보이거나 입력 변수 중요도 분석 결과 고유진동수만을 중요 인자로 예측을 수행한다는 것을 확인함. 이는 DT와 XGBoost 모델이 단순 선형 분류를 수행할 가능성이 크다는 것을 의미하며, 따라서 교량 손상 예측에 있어 한계가 있을 것으로 판단됨.
- 전체 결과 분석 결과, 입력 변수 조합에 고유진동수가 포함된 입력 변수를 적용할 경우, tree-based 알고리즘 모델 중 LightGBM과 CatBoost 모델 사용을 통해 100%에 가까운 손상에측 정확도를 확보할 수 있음.
- 전통적인 손상 예측 모델과의 비교 분석 결과, 본 연구에서 제안한 tree-based 알고리즘이 교량의 손상 개수 및 정도 예측에 있어 우수한 성능을 보이는 것으로 확인함 (약 20%로의 차이).

(5) 교량 손상 및 건전성 평가 결과 분석

- Tree-based 알고리즘 중 RF, XGBoost, LightGBM, 그리고 CatBoost가 비슷한 수준의 예측 성능을 보여줌 (정확도 92% 이상). 이는 머신러닝 기반 교량 빔 손상 상태평가를 위한 최적 예측 모델 선정에 있어 여러 머신러닝 모델에 대한 세밀한 평가가 필요하다는 것을 의미함.
- Tree-based 알고리즘이 개발된 다른 알고리즘들보다 예측 성능이 우수함.
- 이는 강철 빔 손상 유형에 따른 입력 변수 간 관계가 비선형적이기 때문임.
- 고유진동수가 입력에 포함됨에 따라 모델의 예측성능이 급격히 증가함. 그러나 추가분석을 통해 입력 변수의 영향을 조사해야함.
- 이는 머신러닝 모델이 손상 상태 예측 과정에서 하나의 변수(고유진동수)만 고려할 수 있기 때문임.
- 하나의 변수만 고려한 예측은 단순 선형 분류이기 때문에 성능에 한계가 있음.
- 전체 결과를 분석한 결과, CatBoost 모델을 강재 빔 손상 유형을 식별하기 위한 최적 머신러닝 모델로 제안함. (해당 결과를 바탕으로 SCI논문을 작성하였으며, 1월 중 투고완료 계획임.)
- 본 연구에서 수행한 실내 실험은 손상 상태 차이가 명확하여 각 손상에 대한 고유진동수 값 차이 또한 명확함. 따라서, 고유진동수를 입력변수로 고려한 경우 100%에 가까운 정확도를 보임. 그러나 실 교량에서는 손상이 발생해도 고유진동수 차이가 명확하지 않은 경우가 대부분이기 때문에 고유진동수를 고려한 예측 결과의 정확도는 실 교량의 데이터를 통해 면밀히 분석할 필요가 있음.




그림 92. 제안된 tree-based 알고리즘을 활용한 교량 손상 및 건전성 평가 절차

(6) 교량 구조물 손상 상태 정량화 절차 제안

○ 제안한 손상 상태 절차의 우수성

- 본 연구에서 도출한 결과를 바탕으로 교량 손상 상태 정량화 절차를 제안함 (그림 93).
- 제안한 흐름도(그림 93)에 묘사된 바와 같이 다양한 측정(가속도, 변형률, 변위, 고유진동수) 변수 조합에 따른 최적의 측정 신호 처리 방법 및 머신러닝 알고리즘을 선택할 수 있음.
- 선택된 조합에 대한 최소 정확도를 상시로 확인할 수 있고 이를 통해 손상 예측에 대한 정확도를 향상시킬 수 있음.
- 고려된 절차를 통해 최소 92%에서 최대 100%까지의 손상 상태 예측 정확도를 확보할 수 있음.
- 대상 구조물 손상 상태 최종 분류 값을 통해 교량의 손상 상태를 높은 정확도로 정량적으로 평가할 수 있음.




그림 93. 제안된 머신러닝 기반 교량 손상 상태 정량화 절차

○ 정량적 평가 방법

- 본 연구과제를 통해 개발된 머신러닝 알고리즘들을 종합적으로 적용하여 대상 구조물을 정량적으로 평가하는 방법을 제안함.
- 측정을 위한 센서 종류 (가속도계, 변위계, 변형률계) 선택 후, 제안된 정량화 절차 (그림 93과 표 21)에 따라 신호 처리, 알고리즘 분석을 통해 대상 교량의 손상 개수 및 정도에 따른 손상 상태를 분석 및 정량화함.
- 본 연구에서 제안한 교량 손상 평가 방안 및 절차에 대한 예시는 표 21에 묘사함.

표 21. 정량적 평가 방법

1단계	사전 조사 단계
	○ 대상 구조물 손상 상태 조사가 필요함. ○ 조사를 통해 대상 구조물 손상 상태를 분류함.
2단계	실험 set-up 단계
	○ 측정 센서 선택 - 현장 상황에 맞게 센서 종류 선택함. (가속도, 변형률, 변위) ○ 측정 위치 및 개수 - 1차년도 때 개발한 계측 지점 및 개수 최적화 방법을 적용하여 결정함.
3단계	측정 시작 및 데이터 처리 단계
	○ 센서 종류별 데이터를 확보함. ○ 변위 데이터 - 실측 변위 데이터가 없는 경우, 1차년도때 개발한 변위 예측 알고리즘을 사용한 예측 변위 데이터 또는 3차년도 실내 실험에서 적용한 가속도로부터 계산된 변위 데이터 중 선택하여 사용함. ○ 고유진동수 - 측정된 센서 데이터 FFT 분석을 통해 고유진동수 값을 계산함.
4단계	손상 상태 평가 전 설정 사항 선정 단계
	○ 계측 데이터 종류에 따른 입력 변수 조합을 선정함. - 예: 가속도(A), 변형률(S), 그리고 변위(D) 데이터 확보 → 입력 변수 조합 (AS, AD, ASD) 선택함. ○ 본 연구과제를 통해 제안된 새로운 변수인 a/B 값을 선정함. ○ 손상 상태 평가 알고리즘을 선택함. - 최적 알고리즘으로 제안하는 CatBoost 모델을 우선 적용함.
5단계	설정 사항을 적용하여 예측 수행 단계
	○ 1~4단계에서 설정한 사항을 적용하여 예측을 수행함. ○ 예측 결과의 정확도가 낮을 경우 다른 4단계에서 선정된 사항을 변경함. - 그림 93을 통해 a/B 값과 적용 가능 알고리즘을 확인한 후 기존 적용사항과 다른 경우의 수를 적용함.
6단계	대상 구조물 정량적 평가 단계
	○ 예측 결과를 통해 대상 구조물 상태를 정량적으로 평가함. ○ 3차년도 실내 실험을 예시로 설명함. - 예측 결과 손상 상태‘1’로 분류 : 대상 구조물 손상이 없는 상태 - 예측 결과 손상 상태‘2’로 분류 : 깊이 1mm의 손상이 있는 상태 ⋮ - 예측 결과 손상 상태‘11’로 분류 : 깊이 2mm의 손상이 8개 있는 상태 - 예측 결과 손상 상태‘12’로 분류 : 깊이 2mm의 손상이 10개 있는 상태

12) GUI 기반 모니터링 프로그램 개발

- 개발 AI 알고리즘을 탑재하여 실시간으로 교량의 거동 예측 및 건전도를 그래픽으로 보여주는 프로그램을 개발함.

(1) 인공지능 연계 모듈 고도화

- 구조물 건전도 측정 인공지능 모델과 Web 기반 모니터링 시스템을 통합함.
- 교량 구조물 3D 모델을 활용하여 시각화할 수 있도록 3D 모델 연동함.
- AI 건전도 측정 모델을 활용하여 건전도 판단 결과를 연동할 수 있도록 SW 통합함.



그림 94. 대상 구조물 3D 모델

(2) 통합 모니터링 시스템 구축

- AI 모델과 통합모니터링 시스템이 연동할 수 있도록 아키텍처 구성함.
- Matlab으로 개발된 AI 모델의 활용성을 높이기 위하여 파이썬 기반의 웹 아키텍처 개발함.
- Web 기반 통합 모니터링 시스템 구축함.
- 교량의 거동을 시각화할 수 있는 3D 모델 시각화 모듈 개발함.

① 전체 시스템 아키텍처




그림 95. 시스템 아키텍처

- 전체 시스템은 화면을 담당하는 Front, 인공지능모듈과 로직을 담당하는 Back, 그리고 데이터를 저장하는 DB로 구성하였음.
- DB는 사용자정보 교량정보 등 정형화된 데이터를 저장하는 DB와 교량에 부착된 센서로부터 송신되는 온도, 변형율 등에 대한 시계열 데이터를 저장하는 DB로 2중화 하여 구성함.
- Front : Vue.js의 낮은 러닝커브와 Component 재사용성 등의 장점을 활용하기 위해 Vue.js를 화면영역의 프레임워크로 선택함.
- jwt를 통해 토큰을 발행하여 인증, 인가 시스템을 구축함.
- Back : 머신러닝을 비롯한 인공지능 기술들은 주로 구글에서 오픈소스로 공개한 Tensorflow를 통해 개발되는데 이 개발환경은 Python을 기반으로 구현되어 있음.
- 따라서 Python으로 구현된 Django를 RESTful API로 사용하여 인공지능 기술을 탑재하는데에 무리가 없도록 함.
- 또한 Rest Framework를 사용하여 데이터베이스에 데이터를 입력하고 출력하는데에 복잡한 과정을 거치지 않도록 구성함.
- DB1 : 회원 관리 등의 일반적인 웹 애플리케이션의 비즈니스에 적합한 MySQL을 사용함.
- Django에서도 간단한 설정을 통해 MySQL에 접속할 수 있어 연동성이 좋도록 구성함.
- DB2(시계열DB) : 센서에서 전달된 다량의 데이터를 처리하는 것을 전담하기 위해 시계열 데이터를 별도로 두어 사용하기로 하였으며 InfluxDB를 선택함.
- 시계열 데이터베이스는 Chronograf라는 시각화툴을 사용해 관리자가 따로 모니터링할 수도 있음.
- API인 Django에서도 Python 라이브러리를 설치해 바로 InfluxDB를 연결하고 사용할 수 있도록 함.

② 시스템 구성 기술요소




그림 96. 시스템 아키텍처

○ Vue.js

- 2세대 Javascript 프레임워크들 중에서 가장 손쉽게 배울 수 있는 기술임.
- 로직과 UI의 분리를 위해 설계된 MVVM(Model-View-ViewModel) 패턴을 기반으로 디자인되었으며, 재사용이 가능한 UI들을 묶어서 사용할 수 있음.
- DOM 요소가 많아지면 Javascript로 DOM을 핸들링하는 일이 무거워지므로 DOM과 비슷한 구조로 Javascript를 만들며 이것은 진짜 DOM과는 달리 메모리에 올라가있는 것이기 때문에 비교적 매우 빠른 성능을 보여줌.
- Vue.js가 Virtual DOM을 수정하면 DOM을 수정하는 것보다 빠르게 수정할 수 있음.
- Vue.js는 Virtual DOM이 변경될 때마다 진짜 DOM과 비교해서 차이를 찾고 차이가 있는 부분의 DOM만 수정하는 동작을 수행하여 효율적임.




그림 97. vue의 인스턴스 관리 체계

- Component : 화면에 비쳐지는 View의 단위를 쪼개어 재사용이 가능한 형태로 관리하며 vue 확장자의 단일 파일에 HTML, Javascript, CSS 코드로 구성하여 사용함.
- Component는 생명주기를 가지며 크게 Creation, Mounting, Updating, Destruction으로 나눌 수 있음.
 - Creation : 컴포넌트 초기화 단계
 - Mounting : DOM 작성 단계
 - Updating : 상태 변화로 인한 렌더링 단계
 - Destruction : 소멸 단계
- Vuex : Virtual DOM을 관리하기 위한 매니저이다. 앱이나 웹을 이루는 개별 요소들의 정보가 변경되는 지를 확인하고, 해당 값들을 업데이트 시켜주는 역할 수행함.

- Vue CLI : Vue Command Line Interface의 약자로서, 프로젝트를 자동으로 생성/세팅해주는 자동화 역할을 함.
- 웹개발에 사용되는 여러 기능들을 모아둔 Webpack을 자동으로 모아 간단하게 몇 번의 클릭만으로 기본적인 세팅을 해주는 역할을 하며, NPM을 통해 동작됨.
- Vue Router : 개별적인 Vuex가 돌아다니며 확인을 해야할 Virtual DOM들을 향해 이동할 통로의 역할을 함.
- Vuex 상에 개별 Component들을 올려놓고 그것을 Router를 통해 간단히 끌어다가 다른 곳에서 반복적으로 사용할 수 있음.




그림 98. 서버 기술 아키텍처

○ Django

- Python으로 만들어진 무료 오픈소스 웹 애플리케이션 프레임워크로서, 기본적인 구성요소들이 구현됨.
- MTV패턴을 사용함. MVC와 유사하며, View 대신 Template, Controller 대신 View라고 표현함.
 Model : DB에 저장되는 데이터
 Template : 사용자에게 보여지는 UI
 View : 데이터를 처리하고 Template에 데이터를 전달하는 역할
- 강력한 ORM(Object Relational Mapping, 객체 관계 매핑)을 지원하며 이것은 객체와 관계형 DB를 연결해주는 개념임.
- 직접 SQL 쿼리를 작성하지 않아도 Python 코드로 DB를 조작 가능하도록 하므로 개발자가 애플리케이션의 로직 작성에 집중할 수 있도록 도움을 줌.
- 소스의 변경 사항을 자동으로 반영하며, py파일의 변동을 감시하여 변경이 감지될 경우 변경 내역을 자동으로 반영해줌.
- 따라서 개발 도중에 코드를 변경할 때마다 수동으로 웹서버를 재시작할 필요가 없음.




그림 99. 인공지능 모델 교환 기술 적용

○ ONNX 교환 포맷

- ONNX는 기계 학습 모델을 나타내기 위해 구축된 개방형 형식임.
- ONNX는 기계 학습 및 딥 러닝 모델의 빌딩 블록인 공통 연산자 집합과 AI 개발자가 다양한 프레임워크, 도구, 런타임 및 컴파일러와 함께 모델을 사용할 수 있도록 하는 공통 파일 형식을 정의하고 있음.
- 주관기관인 연세대학교에서 개발한 교량 AI 모델은 MATLAB서 개발된 모델임.
- 이를 웹시스템에 바로 연동하여 시스템에 유연하게 탑재하여 사용할 수 있도록 개방형 모델형식인 ONNX를 사용함.
- 연대에서 MATLAB에서 AI 모델을 개발후 ONNX 포맷으로 Export하고 이를 에이펙스소프트에서 개발한 프레임웍에 탑재하여 인공지능 모델을 기동할 수 있도록 구성함.

○ Rest Framework

- Django 안에서 RESTful API 서버를 쉽게 만들도록 도와주는 라이브러리이며 Serializer를 제공함.
- Serializer는 데이터를 json 형태로 변환해주는 기능임.
- 화면에서 넘어온 json 데이터를 따로 가공하지 않아도 비즈니스 로직에서 DB로 입력하는 것이 가능하게 해줌.

○ MySQL

- 전세계적으로 가장 널리 사용되고 있는 오픈소스 관계형 데이터베이스 시스템임.
- 표준 데이터베이스 질의언어 SQL을 사용하며 매우 빠르고 유연하며 사용하기 쉬움.




그림 100. 시계열DB InfluxDB 내부 구조

○ InfluxDB(시계열 데이터베이스)

- 많은 쓰기 작업과 쿼리 부하를 처리하기 위해 2013년에 Go 언어로 개발된 오픈소스 시계열 데이터베이스이며 TICK Stack(Telegraf, InfluxDB, Chronograf, Kapacitor)의 필수 컴포넌트 중 하나임.
- InfluxDB는 많은 시계열 데이터베이스들 중에서 가장 유명하고 많이 사용되는 데이터베이스임.
- 교량의 센서에서 계속된 정보는 대표적인 시계열 정보로서 시간에 따라서 많은 데이터가 축적되는 특징을 가지고 있음.
- 향후 여러교량과 많은 센서로부터 계속정보를 받게 되면 이를 저장하고 활용하기 위해서는 시계열 DB가 필수적임.
- 특히 교량의 수명은 수십년 이상이므로 수명기간동안 계속된 데이터를 저장하고 장기적인 거동을 분석하기 위해서는 시계열 DB가 없이는 많은 기술적인 작업이 필요하게 되어 시계열 DB의 활용이 필수적임.

1) TICK Stack : InfluxDATA에서 나온 4가지 오픈소스 컴포넌트들을 기반으로 구축한 시스템임.

Telegraf : Metrics와 Events를 수집하고 리포팅하는 모듈

InfluxDB : 시계열 데이터베이스

Kapacitor : Real-time 스트리밍 데이터 전송 엔진

Chronograf : 시각화 도구

- 2) InfluxDB의 핵심 목적은 시간에 따른 데이터(시계열 데이터)의 처리이다. InfluxDB는 데이터를 처리하여 새롭게 저장하는 Down Sampling(다운 샘플링)을 일정 주기마다 실행되도록 하는 Continuous Query(연속적인 쿼리)를 사용할 수 있음.
- 3) Influx DB의 핵심 목적은 시간에 따른 데이터의 삽입과 조회이므로 직접 Delete를 이용하는 경우는 거의 없지만 데이터가 계속해서 쌓이면 저장 공간 및 처리 속도 등에 문제가 생기므로 데이터를 자동으로 삭제해주는 Retention Policy(보존 정책)를 지원하고 있음.
- 4) Retention Policy란 오래된 데이터를 자동으로 삭제해주는 정책으로서 데이터베이스 단위로 정의되며 일반적으로 1개의 데이터베이스는 여러 개의 보존 정책을 가지고있음. 만약 별도의 설정을 하지 않았다면 autogen이라는 기본 정책으로 적용된다. autogen은 보존 기간이 무제한임.

③ 시스템 확장에 유연한 Micro Service 구축

- 업무영역과 시계열 데이터 관리 영역을 분리하여 데이터베이스를 MySQL, InfluxDB로 독립적으로 구축함.
- 또한 기술적으로는 End User(사용자)가 사용하는 화면과 로직이 들어가는 비즈니스를 분리하여 구현함.
- 업무영역의 역할은 사용자 관리, 교량등록, 교량 관리 등 일반 Web 업무 시스템 기능에 해당하는 영역으로 구성함.
- 시계열 데이터 관리 영역은 교량의 센서(혹은 교량 관리시스템 API)에서 계측된 정보를 저장하고 활용하는 영역으로 구성함.
- 화면에서는 UI와 사용자에게 집중된 서비스를 제공함.
- 로직을 담당하는 비즈니스를 구현한 API 서버에서는 사용자 등록과 로그인 등의 일반적인 서비스를 비롯하여 인공지능 로직 처리와 데이터 등록, 수정 등의 전문적인 서비스까지 처리함.
- API 내에서도 각 영역은 독립적인 App의 형태로 구현되어 있으므로 기능의 분리 및 분산 처리가 충분히 가능함.
- 따라서 상용 시스템에 확장이 가능한 유연한 형태의 설계임.




그림 101. 전통적인 Monolithic 구조와 Micro-service 구조 비교

- MSA(MicroService Architecture) : 정확한 정의는 없으나, 작고 독립적으로 배포 가능한 각각의 기능을 수행하는 서비스로 구성된 프레임워크라고 할 수 있음.
- 마이크로서비스는 완전히 독립적으로 배포가 가능하고, 다른 기술 스택(개발 언어, 데이터베이스 등)이 사용 가능한 단일 사업 영역에 초점을 둠.

(3) 실시간 계측값 활용 시스템 개발

- 교량의 매설된 계측기로부터 시계열 신호를 받아서 모니터링 할 수 있도록 체계 구축함.
- 시간에 따른 교량의 거동을 계측값을 DB화하여 시계열 데이터 처리 시스템 구축함.
- 교량 계측 시계열 데이터를 샘플로 DB에 구축하여 파일럿 시스템 구축함.
- 구조물의 계측값과 예측값, 통합진단을 동시에 서비스할 수 있는 기능을 개발함.
- 향후 계측기가 시계열DB에 계측값을 Upload 할 수 있도록 환경 구성 시 실시간 모니터링이 가능하도록 구축함.

① 통합모니터링 시스템에 계측치 연동 및 시각화 개발




그림 102. 통합 시스템 대시보드 화면




(a) 대상 구조물 모델 및 측정 데이터 값 표출



(b) 위치별 센서 측정 데이터 그래프



(c) 인공지능을 통해 예측한 위치별 변위 그래프



(d) 인공지능을 통해 예측한 손상 상태 예측 결과

그림 103. 통합 시스템 결과 화면

② 전문적인 지식이 없는 사용자도 쉽게 이용할 수 있도록 개발된 UI

- 직관적인 인터페이스를 통해 따로 학습하지 않더라도 사용할 수 있도록 구현함.
- 비언어적 표현들은 자주 사용되는 보편적인 픽토그램을 활용하였고 필요에 따라 간단한 문자와 함께 표시함.
- 픽토그램 : 그래픽 상징으로서 그림문자로 되어 있어 언어가 다르더라도 누구나 바로 쉽게 이해할 수 있는 시각언어임.
- 세계적으로 효과적인 커뮤니케이션 수단으로 인정받고 있으며 가장 핵심적인 부분을 시각적으로 쉽게 표현함으로써 전달하므로 효과적임.
- 의미하는 내용을 상징적으로 단순하게 시각화하기 때문에 사전에 교육을 받지 않았더라도 모든 사람이 즉각적으로 이해할 수 있도록 구성됨.




그림 104. 통합 시스템 노드(센서)별 조회 화면

(4) 통합모니터링 시스템의 장점 및 활용방안

- 1~2차년도에 개발한 알고리즘이 프로그램에 적용되어 실시간으로 평가 결과(변위 예측 및 손상 상태 예측)를 확인할 수 있음.
 - 3차년도에 개발한 알고리즘 적용을 통해 교량의 손상상태평가 결과를 효율적이고 경제적으로 수행할 수 있음.
 - 본 연구에서 제안한 통합 손상 평가 방안은 실내 실험(교량 모형)부터 실제 교량 등 다양한 건설 구조체에 적용이 가능하며, 항공, 기계 분야로의 적용이 가능함.
 - 향후 본 연구과제에서 개발한 머신러닝 알고리즘보다 성능이 우수한 알고리즘이 개발될 경우, 손쉽게 업데이트가 가능할 것으로 판단되며, 이를 통해 추후 높은 정밀도와 유연성을 지닌 교량 손상 진단 플랫폼으로 개발할 예정임.
-

3. 연구개발과제의 수행 결과 및 목표 달성 정도

1) 연구수행 결과

(1) 정성적 연구개발성과

연차	세부 연구 목표	성과
1차 년도	연구 및 실험 대상으로 하는 거더 교량 수치해석	○ 실측 처짐 및 이론값과의 비교를 통하여 수치모델의 검증이 적절하게 이루어짐.
	검증된 수치해석 결과 데이터를 이용하여 거동 예측 AI 알고리즘 학습	○ 수치해석을 통하여 얻은 데이터(변형률, 처짐)를 AI에 학습시켰을 때, 거동(처짐) 예측 정확도가 95% 이상인 것으로 나타 남.
	실제 교량에 정적·동적 하중 재하실험 (학습된 AI 알고리즘 검증)	○ 공용 중인 교량의 변형률, 처짐 계측실험 을 하였고, 이를 AI에 학습시켰을 경우, 거동 예측 정확도가 목표했던 오차 10% 이내인 것으로 나타남. ○ 온도효과, 계측된 값에 존재하는 noise로 인하여 거동 예측 정확도가 수치데이터를 이용하는 경우보다 상대적으로 낮았으나, 이를 보완하여 정확도 높임. (SCI 1편 계 재)
2차 년도	결함 반영된 거더 교량 수치해석	○ 일반적으로 교량 결함이라고 함은, 콘크 리트 균열, 강재 부식 등을 대표적으로 들 수 있음. ○ 콘크리트 균열을 탄성계수의 감소로 고려 하고, 강재의 부식은 단면의 감소로 반영 함. ○ 본 연구에서는 탄성 계수 감소와 단면 감 소를 구조물에 반영하는 다양한 결함 시나 리오를 작성함. 결함을 반영한 수치 모델 을 이용하여 해석을 수행. 빔의 탄성계수 를 감소시켜, 오일러 빔 이론을 이용하여 이론 처짐을 구하였고, 해석결과와 비교로 부터 1%이하의 오차가 계산됨.
	수치 해석 결과 데이터를 이용하여 결함 예측 AI 알고리즘 학습	○ 다양한 결함 시나리오(결함 위치, 결함 크기)를 반영한 수치 모델로부터 데이터 (변위형상)를 획득. 획득한 데이터를 이용 하여 패턴인식 AI 알고리즘에 학습을 수행 하였고, 92% 이상의 학습 결과 획득함. ○ AI 알고리즘의 입력값으로 변위형상을 선 택한 이유는, 1차년도에 변형률로부터 변 위를 예측하는 연구를 수행하였기 때문에, 예측된 변위로부터 결함에 대한 정보를 예 측할 수 있는지 보기 위함임.

3차 년도	학습된 AI 알고리즘 검증	○ 학습된 AI 알고리즘에 학습에 사용되지 않은 변위 형상을 입력하였을 때, AI 알고리즘이 결함 정보(위치, 정도)를 예측할 수 있는지 검증. 검증 결과 결함의 위치와 정도를 96% 이상의 정확도로 예측할 수 있음이 확인됨.(SCI 1편 게재)
	AI 활용 거동 예측 및 건전성 평가 통합 알고리즘 개발	○ 변형률로부터 변위를 예측하고, 예측된 변위로부터 대상 구조물의 결함 정보를 예측할 수 있는 알고리즘을 개발함. ○ 따로따로 수행 가능한 알고리즘을 통합함으로써 하나의 입력 데이터로 두 가지 예측 결과를 동시에 획득 가능함.
	거더 교량에 대하여 실제 교량 또는 실내 실험을 통하여 통합 알고리즘 기술시범	○ 실제 교량 데이터를 통합 알고리즘에 적용하여 변위 예측 및 결함 정보를 예측함. ○ 실제 교량의 결함 정보에 대해 조사가 이뤄지지 못해 예측 결과를 검증하지는 못함. ○ 1~2차년도에 수행한 결과를 바탕으로 최소 90%이상의 예측 정확도를 보일 것으로 보임. ○ 알고리즘의 예측 속도 향상을 위해 tree-based 알고리즘을 개발하였고, 실내 실험을 통해 성능을 검증함. ○ 검증 결과 손상 상태 예측에 대해 높은 정확도(98%)를 보이며 예측 속도도 빠른 최적 알고리즘을 개발함. (SCI 2편 게재 완료, 추가 1편 작성 완료 및 1월 중 투고 완료 계획)
	AI 알고리즘 탑재된 프로그램 개발	○ 개발 알고리즘을 프로그램에 적용하여 실시간 측정 데이터로부터 예측을 수행함. ○ 예측 결과를 프로그램을 통해 확인 가능함. ○ 모형 교량 및 실험교량 외의 다른 구조물에도 적용 가능한 프로그램을 개발함.
	예측 거동 시각화	○ 개발 프로그램에서 실시간 측정데이터를 활용하여 예측 변위를 시각화(그래프)함. ○ 손상예측 결과를 시각화(매트릭스)함. ○ 시각화 자료를 통해 교량 상태 모니터링이 가능함. ○ 비전문가도 해석 가능하도록 UI를 손쉽게 구성함.

(2) 정량적 연구개발성과

○ 정량적 연구 목표 및 성과

(단위 : 편,건,명)

연도	국외논문게재			국내논문게재			특허출원			특허등록			소프트웨어		인력양성		
	SCI	비SCI	계	SCI	비SCI	계	국내	국외	계	국내	국외	계	등록	계	석사	박사	계
목표	3	2	5	0	3	3	2	0	2	1	0	1	3	3	3	3	6
달성	4	0	4	0	0	0	1	0	1	1	0	1	3	3	1	3	4
진행 중	1	0	1	0	3	3	1	0	1	0	0	0	0	0	0	1	1
비고	SCI 1편 초과달성 및 추가 SCI 1편 1월 중 투고 완료 계획			국내 비 SCI 논문 3편 작성 중			건전성 평가 방법으로 특허출원 준비 중								2022-1학기 박사 졸업 예정 1명		

○ 미달성 양적 성과에 대한 달성 계획

- 비 SCI논문 3편

: 영구 거푸집 공사용 3D 섬유 강화 시멘트계 복합 재료를 이용한 RC구조물 급속 시공법 개발

: 부식 관로 3D 스캔 포인트 클라우드를 통한 부식부 세그멘테이션

: 디지털이미지를 이용한 사장교 케이블의 장력 평가

: 위 세 개의 주제로 국내 논문 작성 중에 있으며, 8월안에 투고예정임.

- 특허 출원 : 3차년도에 개발한 알고리즘을 통한 건전성 평가 방법에 대해 출원 진행 중에 있으며, 5월안에 출원신청 진행 예정임.

- 인력양성 : 2022-1학기 박사 졸업 예정임(8월 예정).

(3) 세부 정량적 연구개발성과

[과학적 성과]

☐ 논문(국내외 전문 학술지) 게재

번호	논문명	학술지명	주저자명	호	국명	발행기관	SCIE 여부 (SCIE/비SCIE)	게재일	등록번호 (ISSN)	기여율
1	Artificial Neural Network for Vertical Displacement Prediction of a Bridge from Strains (Part 1): Girder Bridge under Moving Vehicles	Applied sciences	김문겸, 문현수	9(14)	스위스	MDPI	SCI	2019.07.18.		25%
2	Artificial Neural Network for Vertical Displacement Prediction of a Bridge from Strains (Part 2): Optimization of strain-measurement points by a Genetic Algorithm Under Dynamic Loading	Applied sciences	김문겸, 문현수	10(3)	스위스	MDPI	SCI	2020.01.22.		25%
3	Optimization of Position and Number of Hotspot Detectors Using Artificial Neural Network and Genetic Algorithm to Estimate Material Levels Inside a Silo	Sensors	김문겸, 이정훈	21	스위스	MDPI	SCI	2021.06.28.		25%
4	Application of Artificial Neural Network to Predict Dynamic Displacements from Measured Strains for a Highway Bridge under Traffic Loads	Journal of Civil Structural Health Monitoring	김문겸, 문현수		독일	SPRINGER HEIDELBERG	SCI	2021.10.22	2190-5452	25%
5	Assessment of Multi-Type Damage in Steel Beam using Dynamic Responses Trained by Machine Learning Algorithms	Engineering Structures (목표)	김문겸, 이정훈				SCI	투고완료		

□ 국내 및 국제 학술회의 발표

번호	회의 명칭	발표 내용	발표자	발표 일시	장소	국명
1	2019 대한토목학회 학술대회	교량의 처짐 곡선 예측을 위해 필요한 변형률 계측 위치 및 개수 최적화를 위한 인공지능의 적용	장우진	2019.10.17.	평창 알펜시아	한국
2	2019 해상교량 국제심포지엄	Artificial Intelligence Aided Estimation of a Bridge Displacements from Strains and Optimization of a Strain-Measurement Points	문현수	2019.10.24.	전남도청	한국
3	2020 대한토목학회 학술대회	고속도로 교량의 축방향 변형률로부터 수직방향 처짐을 예측하기 위한 신경망의 적용	문현수	2020.10.22.	제주도	한국

□ 기술 요약 정보

번호	연도	기술명	요약 내용	기술 완성도	등록 번호	활용 여부	미활용사유	연구개발기관 외 활용 여부	허용방식

□ 보고서 원문

번호	연도	보고서 명	발간일	등록 번호

□ 생명자원(생물자원, 생명정보)/화합물

번호	생명자원(생물자원, 생명정보)/화합물 명	등록/기탁 번호	등록/기탁 기관	발생 연도

[기술적 성과]

□ 지식재산권(특허, 실용신안, 의장, 디자인, 상표, 규격, 신품종, 프로그램)

번호	구분	지식재산권 등 명칭 (건별 각각 기재)	국명	출원			등록			기여율	활용 여부
				출원인	출원일	출원번호	등록인	등록일	등록번호		
1	특허	정밀한 변형률-변위 예측을 위한 유전자 알고리즘과 AI 기술을 적용한 구조물의 계측 위치 및 개수 결정 방법	대한민국	문현수	2021.07.14.	제 10-2021-0091986 호	문현수	2021.11.24.	제 10-2332188 호	100%	

○ 지식재산권 활용 유형

번호	제품화	방어	전용실시	통상실시	무상실시	매매/양도	상호실시	담보대출	투자	활용 예정	기타

□ 저작권(소프트웨어, 서적 등)

번호	저작권명	창작일	저작자명	등록일	등록번호	저작권자명	기여율
1	변형률 데이터 기반 교량 거동 시뮬레이션 모듈	2019.10.30.	에이펙스소프트	2019.10.30.	ASSET_0006452	(주)에이펙스소프트	30%
2	변형률 데이터 기반 교량 거동 시뮬레이션 인공지능 연계 모듈소프트웨어등록	2020.10.30.	에이펙스소프트	2020.10.30.	ASSET_0007082	(주)에이펙스소프트	30%

3	변형률 데이터 기반 교량 거동 시뮬레이션 및 구조물 예측 인공지능 탑재 통합 모니터링 시스템	2021.12.23.	에이펙스소프트	2021.12.23.	ASSET_000853 4	(주)에이펙스소프트	40%
---	--	-------------	---------	-------------	-------------------	------------	-----

☐ 신기술 지정

번호	명칭	고시일	보호기간	지정번호

☐ 기술 및 제품 인증

번호	인증 분야	인증기관	인증 내용		인증 획득일	국가명
			인증명	인증번호		

☐ 표준화

○ 국내표준

번호	인증구분	인증여부	표준명	표준인증기구명	제안주체	표준종류	제안/인증일자

○ 국제표준

번호	표준화단계 구분	표준명	표준기구명	표준분과명	의장단 활동여부	표준특허 추진여부	표준개발 방식	제안자	표준화 번호	제안일자

[경제적 성과]

☐ 시제품 제작

번호	시제품명	출시/제작일	제작업체명	설치장소	이용분야	사업화 소요 기간	인증기관 (해당 시)	인증일 (해당 시)

☐ 현장적용

번호	적용기술명	적용일	발주기관명	적용 연구개발기관명	적용현장명(장소)
1	교량 거동 예측 알고리즘	2019.09.24.-26	한국도로공사	연세대학교 산학협력단	망상 3교

☐ 기술 실시(이전)

번호	기술 이전 유형	기술 실시 계약명	기술 실시 대상 기관	기술 실시 발생일	기술료	
					발생 연도	발생액(천원)

☐ 사업화 투자실적

번호	연도	투자 자금 성격*	추가 연구개발 투자(천원)	설비 투자(천원)	기타 투자(천원)	합계(천원)

□ 사업화 현황

번호	사업화 방식	사업화 형태	지역	사업화명	내용	업체명	매출액		매출 발생 연도	기술 수명
							국내 (천원)	국외 (달러)		

□ 매출 실적(누적)

번호	사업화명	발생 연도	매출액		합계	산정 방법
			국내(천원)	국외(달러)		
합계						

□ 사업화 계획 및 무역 수지 개선 효과

성과					
사업화 계획	사업화 소요기간(년)				
	소요예산(천원)				
	예상 매출규모(천원)		현재까지	3년 후	5년 후
	시장 점유율	단위(%)	현재까지	3년 후	5년 후
		국내			
		국외			
향후 관련기술, 제품을 응용한 타 모델, 제품 개발계획					
무역 수지 개선 효과(천원)	수입대체(내수)	현재	3년 후	5년 후	
	수 출				

□ 고용 창출

번호	사업화명	사업화 업체명	고용창출 인원(명)		합계(명)
			yyyy년	yyyy년	
합계					

□ 고용 효과

구분			고용 효과(명)	
고용 효과	개발 전	연구인력		
		생산인력		
	개발 후	연구인력		
		생산인력		

□ 비용 절감(누적)

번호	사업화명	발생 연도	산정방법	비용 절감액(천원)
합계				

□ 경제적 파급 효과

(단위 : 천원/년)

구분	사업화명	수입 대체	수출 증대	매출 증대	생산성 향상	고용 창출 (인력 양성 수, 명)	기타
해당 연도							
기대 목표							

□ 산업 지원(기술지도)

번호	내용	기간	참석 대상	장소	인원(명)

□ 기술 무역

(단위 : 천원)

번호	계약 연월	계약 기술명	계약 업체명	계약업체 국가	총 계약액	기 징수액	해당 연도	징수액	향후 예정액	수출/ 수입

[사회적 성과]

□ 법령 반영

번호	구분 (법률/시행령)	활용 구분 (제정/개정)	명 칭	해당 조항	시행일	관리 부처	제정/개정 내용

□ 정책활용 내용

번호	구분 (제안/채택)	정책명	관련 기관 (담당 부서)	활용 연도	채택 내용

□ 설계 기준/설명서(시방서)/지침/안내서에 반영

번호	구 분 (설계 기준/설명서/지침/안내서)	활용 구분 (신규/개선)	설계 기준/설명서/ 지침/안내서 명칭	반영일	반영 내용

□ 신진연구자 채용

번호	채용 연구개발기관명	채용일	근로기간	채용인원(명)	채용인원 중 청년인력(명)

□ 전문 연구 인력 양성

번호	분류	연도	현황(명)										
			학위별				성별		지역별				
			박사	석사	학사	기타	남	여	수도권	충청권	영남권	호남권	기타
1	졸업	2019-2	○				○		○				
2	졸업	2019-2		○			○				○		
3	졸업	2020-1	○				○			○			
4	졸업	2020-1	○				○			○			
5	졸업예정	2022-1	○				○		○				

□ 산업 기술 인력 양성

번호	연도	프로그램명	프로그램 내용	교육 기관	교육 개최 횟수	총 교육 시간	총 교육 인원

□ 다른 국가연구개발사업에의 활용

번호	연도	중앙행정기관명	사업명	연구개발과제명	연구책임자	연구개발비(천원)

□ 국제화 협력성과

번호	구분 (유치/파견)	기간	국가	학위	전공	내용

□ 홍보 실적

번호	홍보 유형	매체명	제목	홍보일

□ 포상 및 수상 실적

번호	종류	포상명	포상 내용	포상 대상	포상일	포상 기관

[인프라 성과]

□ 연구시설·장비

번호	구축 기관	연구시설/ 연구장비명	규격 (모델명)	개발여부 (○/×)	연구시설·장비 종합정보시스템* 등록여부	연구시설·장비 종합정보시스템* 등록번호	구축일자 (YY.MM.DD)	구축비용 (천원)	비고 (설치 장소)

2) 목표 달성 수준

연구 개발 목표	달 성 내 용	달성도(%)
○ 기개발하여 이론적으로 검증된 알고리즘(인공 지능을 활용한 구조물의 실시간 거동예측)을 실제 거더 교량에 적용해보는 실험	○ 결함 반영된 거더 교량 수치해석 - 캔틸레버빔을 대상 구조물로 결함에 대한 연구 수행. 빔의 다양한 위치에 1) 탄성계수 감소 2) 단면적 변화를 결함으로 반영하여 수치해석 수행. 이론 결과와 수치 해석 결과로 자유단 처짐 비교하였을 때, 99% 일치함을 확인. 추가적으로 1차년도에 사용한 거더 교량 모델에도 결함을 반영한 수치해석을 수행중에 있고, 2차년도 종료 전에 교량 수치 해석 데이터를 이용하여 결함을 평가할 수 있을 것으로 판단됨. ○ 수치 해석 결과 데이터를 이용한 결함 예측 AI 알고리즘 학습 - 빔의 변위 형상을 입력값으로, 결함의 위치와 정도를 예측하는 각각의 AI 알고리즘을 개발하여 학습 수행결과, 92% 이상의 학습 정확도가 도출됨. ○ 학습된 AI 알고리즘 검증 - 학습된 AI 알고리즘에 학습에 사용되지 않은 임의의 빔의 변위 형상을 입력하였을 때, 실제 빔의 결함(위치, 정도)와 예측된 결함 정보가 96% 이상으로 예측 정확도를 보임. ○ 실제 거더 교량에 적용 - 1차년도 실험 대상 구조물인 망상 3교 데이터를 개발 알고리즘에 적용하여, 거동 예측 및 결함 예측이 가능함을 확인함. ○ 알고리즘 업데이트 - 손상 예측 알고리즘 업데이트를 통해 손상 상태 예측 최신 AI 알고리즘 개발 및 정량화 방법 개발함. - 업데이트된 알고리즘을 통해 손상 예측 정확도가 최대 98% 이상임을 확인함.	96
○ 공용중인 교량에 적용 가능한 인공 지능형 실시간 거동 예측 및 건전성 평가 프로그램 개발	○ AI 알고리즘 탑재된 프로그램 개발 및 예측 거동 시각화 - 여러 계측 정보/ 예측 정보를 표출할 수 있는 인터페이스 구축하고 이를 활용할 수 있는 기본 플랫폼을 개발함. - AWS 기반으로 플랫폼 프로토타입을 구축하여 3차년도 통합모니터링 시스템 구축의 기술적인 기반을 확보함. - 시각화 모듈은 구조물의 모습과 거동(실측/예측값)을 표출할 수 있도록 구현하여 사용자 편의성을 높여 시각적으로 거동을 판단할 수 있도록 개발함. - 실내실험(교량 모형 구조물) 및 실교량 외의 구조물에도 손쉽게 적용 가능하도록 프로그램을 개발함. - 향후 기개발된 알고리즘보다 우수한 알고리즘이 개발될 시 손쉽게 업데이트할 수 있는 플랫폼을 구축함.	100

4. 목표 미달 시 원인분석

1) 목표 미달 원인(사유) 자체분석 내용

○ 국외 비SCI 논문 2건

- 본 연구과제에서 국외 비SCI 논문 2건을 해외학회에 참가하여 해당 학회 proceeding으로 목표를 달성할 계획이었으나, 해외학회 참가를 하려고 한 2020년부터 현재까지 예상하지 못한 전염병(COVID-19)으로 인해 해외 출국이 불가하여 학회참가 또한 불가능해졌음.
- 위와 같은 이유로 본래 목표치로 잡아놓은 국외 비 SCI 논문 2건을 달성하지 못하였음.

○ 국내 비SCI 논문 3건

- COVID-19로 인해 연구수행 일정에 차질이 생겼고, 이로 인해 목표로 한 성과를 달성하지 못하였음.

○ 특허 출원 1건

- COVID-19로 인한 1~2차년도 특허출원 일정 지연으로 인해 특허등록 일정이 미뤄짐.
-

2) 자체 보완활동

○ 국외 비SCI 논문 2건

- 1~2차년도 연구과제 내용을 통해 목표로 한 SCI 논문 편수보다 한편 더 많은 총 4편의 SCI 논문을 초과로 작성하여 게재 완료하였음.
- 3차년도에 실내 실험을 통한 AI 모델 업데이트를 진행하였고, 이 내용을 통해 SCI 논문을 추가로 1편을 작성 완료하였으며, 1월 중 투고 완료 예정임.
- 또한, 실내 실험을 통해 추가로 진행할 수 있는 연구내용에 대해 용역 참여 연구원인 UNIST와 지속적으로 회의를 진행하였고, 이를 통한 추가 실험 및 SCI 논문 작성을 진행하고 있음.

○ 국내 비SCI 논문 3건

- 국내에서 개최되는 학술대회에 3회 참가하여 연구과제를 통해 개발된 성과에 대해 발표하였음.
- 개발된 알고리즘을 활용해 국내 논문 3편 작성 계획임.

○ 특허 출원

- 추가 특허 출원과 관련해서는 3차년도에 수행한 실험을 통한 결과(정량화 평가 방법)를 활용한 특허 출원 준비중에 있음.
-

3) 연구개발 과정의 성실성

○ 개발 알고리즘 검증

- 개발한 알고리즘을 검증하기 위해 실내 실험 및 실교량을 대상으로 실험을 수행함.
- 다양한 하중 상태의 데이터를 확보함.

○ 개발 알고리즘의 적용 가능성 확인

- 코로나로 인해 3차년도 실교량 실험이 불가능한 상황에서 이전에 확보한 실 교량 데이터를 활용하여 적용 가능성을 확인함.

○ 개발 알고리즘 업데이트를 위한 추가 실험

- 기개발 알고리즘의 해석 속도 향상을 위해 높은 정확도와 빠른 속도를 보이는 tree-based 알고리즘을 개발하여 실내 실험을 통해 비교 분석하였음.
 - 실내 교량 실험을 통해 알고리즘의 우수성을 검증하였고, 이를 통해, 손상예측에 높은 정확성을 지닌 머신 러닝 알고리즘을 추가로 개발함.
 - 실험을 통해 획득한 결과로 SCI 논문 작성 완료 후 투고완료.
-

5. 연구개발성과의 관련 분야에 대한 기여 정도

○ 기술적 측면

- 기존의 건전성 평가는 데이터를 계측하고 시스템 구축하는데 주로 초점이 맞춰져 있음. 또한, 계측된 위치의 정보만 획득할 뿐 데이터 활용 측면에는 조금 미흡한 부분이 있음.
- 본 연구에서는 계측한 데이터를 인공지능을 이용하여 더 의미 있는 데이터로 변환함으로써, 데이터 활용을 극대화함.
- 개발된 인공지능 기술을 활용하게 되면, 센서로부터 계측된 데이터를 실시간으로 손상 정보를 예측할 수 있는 의미 있는 데이터로 예측 및 변환할 수가 있음. 계측데이터는 일반적으로 계측이 쉬운 변형률, 가속도 등을 의미함. 의미 있는 데이터란, 계측된 위치를 포함한 교량 전체의 거동(처짐), 결함 정보(위치, 크기 등)를 말함.
- 예측된 거동을 바탕으로, 직관적으로 구조물의 상태를 파악할 수 있을 뿐만 아니라, 예측된 결함 정보를 바탕으로 최종적으로 구조물의 건전성을 실시간으로 평가할 수 있음.
- 제안한 연구 방법은 모든 유형의 교량에 적용 가능한 기술임. 특히, 인천대교, 광안대교 등 매우 중요한 교량에는 현재 다양한 종류의 센서가 설치되어 다양한 데이터를 실시간으로 모니터링이 진행되고 있는 상황임. 본 연구과제를 통해 제안한 방법을 활용하면, 소수 종류의 센서를 바탕으로 다양한 데이터(전체 거동, 결함 정보 등)를 정확하게 파악할 수 있음.

○ 사회적 측면

- 개발된 연구가 공공 인프라 구조물에 적용되면, 시민들 개개인이 소지한 휴대폰 어플리케이션 등을 통하여 이용중에 있는 인프라 구조물의 거동과 건전성 상태를 실시간으로 확인할 수 있음. 따라서, 보다 높은 심리적 안정감을 줄 수 있을 것으로 기대됨.
 - 또한, 구조물의 이상 징후가 발생하였을 때, 휴대폰 알림 등을 실시간으로 알려주면 만약의 상황에 큰 피해를 미리 예방할 수 있을 것으로 기대됨.
-

○ 경제적 측면

- 제안한 연구개발이 이루어지면 건전성 평가를 위하여 설치해야 하는 센서 계측 비용을 획기적으로 줄일 수 있음. 기존 공공 인프라 구조물의 건전성 평가는 대부분 오랜 기간 축적된 계측데이터의 변화 양상을 바탕으로 구조물의 건전성을 평가함. 이러한 기존 방법은 다양한 종류의 센서를 필요로 하고, 다량의 데이터 중에서는 불필요한 데이터도 내포하고 있음.
- 본 연구에서 제안한 AI 알고리즘은 학습을 통하여, 한가지의 데이터로부터 다양한 종류의 데이터를 예측할 수 있음. 따라서, 새로 신설되는 교량에 대하여 기존처럼 다양한 종류의 데이터를 설치해야 하는 비용을 획기적으로 줄일 수 있음.
- 데이터의 비효율적인 사용을 피하기 위하여, 인공지능을 이용해 구조물의 거동을 파악하기 위하여 필요한 계측 데이터의 수와 위치를 최적화하는 방법을 포함함. 최소의 계측 데이터로, 다양한 형태의 어떤 데이터도 추출할 수 있기 때문에 최소 비용으로 거동을 파악할 수 있음.
- 실시간 건전성 평가로 인하여 적절한 유지·보수 등을 통하여 비용 절감이 기대됨. 일시적인 구조물의 결함 또는 노후화 등으로 인한 영구적인 결함을 실시간으로 파악하여 대형 사고를 미리 예방할 수 있고, 적절한 유지·보수 작업이 이루어짐으로써 구조물의 수명 연장을 기대할 수 있음.

○ 활용적 측면 : 다양한 구조물에 적용 가능

- 개발하고자 하는 연구는 특정 구조물에 대한 건전성 평가만을 의미하지 않음. 초고층 구조물, 초대형 저장탱크, 그리고 빌딩 등 대부분의 구조물의 처짐과 건전성 평가는 매우 중요하고, 그 과정이 크게 다르지 않음.
 - 따라서, 개발한 통합 알고리즘을 이용하면 사회의 주요 공공 인프라 구조물에 모두 적용이 가능할 것으로 기대함. 이에 따라 전체적으로 사회적으로 기본적인 안전 수준이 한 단계 업그레이드될 것으로 기대함.
-

6. 연구개발성과 관리 및 활용 계획

○ 개발한 프로그램의 실용화 및 사업화

- 본 연구에서는 교량의 거동과 결함(위치, 정도)을 예측하는 AI 기반의 알고리즘 및 프로그램을 개발하여, 실험을 통해 실용성을 검증함. 기존 또는 신축되는 교량에서 계측된 변형률 데이터가 미리 학습된 AI 알고리즘에 입력되면 실시간으로 교량의 거동을 예측하고, 이와 동시에 교량에 발생한 결함 정보(위치, 정도)를 정량적으로 판단할 수 있음.
- 연구과제를 통해 개발한 AI 기반 건전도 평가 알고리즘은 그 대상을 거더 교량으로 하여 검증을 수행함. 하지만, 제안한 방법은 교량뿐만 아니라, 다양한 구조물에도 적용이 가능한 방법이기에 때문에 과제 종료 후에는 다경간 또는 케이블교 등의 특수 교량에도 적용하여 실용성을 확인해 보고자 함.
- 연구 성과를 바탕으로 구조물 계측 업체와의 협업을 통하여 기존 또는 신설되는 교량 건전성 평가에 직접 적용하는 사업화를 진행하고자 함.

○ 휴대용 모바일 장비를 이용한 건전성 평가 후속 연구

- 개발된 기술을 구조물에 설치된 센서가 아닌, 센서(GPS, 가속도계 등)가 내장된 스마트폰에서 계측된 데이터를 개발한 AI 알고리즘에 적용하여 건전도를 평가하는 방법에 대한 후속 연구를 진행할 계획에 있음.
- 후속 연구가 성공적으로 진행된다면, 새로운 센서의 설치 없이 일상생활에서 스마트폰 등을 통하여 계측되는 모든 데이터가 다양한 인프라 구조물의 건전도를 평가하는데 활용될 수 있을 것으로 판단됨.

○ 실제 현장에 존재하는 다양한 유형의 교량 및 구조물에 적용

- 본 연구에서는 인공지능 알고리즘을 이용하여 실제 교량에 대하여 시험 및 검증을 수행함.
 - 연구 성과를 바탕으로 다양한 유형의 교량 및 구조물에 대하여 수치해석 및 실제 현장 실험을 통하여 개발한 알고리즘의 우수성을 확인해 보고자 함.
 - 다양한 구조물에 알고리즘을 적용해봄으로써 기존의 건전성 평가 방법보다 경제적·기술적 측면에서 보다 나은 경쟁력을 갖출 수 있을 것으로 판단됨.
-

7. 참고 문헌

1. Moses, F. Weigh-in-motion system using instrumented bridges. *J. Transp. Eng.* 1979, 105, 233-249.
2. Lee, J.-J.; Shinozuka, M. Real-time displacement measurement of a flexible bridge using digital imageprocessing techniques. *Exp. Mech.* 2006, 46, 105-114.
3. Xu, L.; Guo, J.J.; Jiang, J.J. Time-frequency analysis of a suspension bridge based on GPS. *J. Sound Vib.* 2002,254, 105-116.
4. Nassif, H.H.; Gindy, M.; Davis, J. Comparison of laser Doppler vibrometer with contact sensors for monitoringbridge deflection and vibration. *NDT E Int.* 2005, 38, 213-218.
5. Pieraccini, M.; Luzi, G.; Mecatti, D.; Fratini, M.; Noferini, L.; Carissimi, L.; Franchioni, G.; Atzeni, C. Remotesensing of building structural displacements using a microwave interferometer with imaging capability.*NDT E Int.* 2004, 37, 545-550.
6. Stephen, G.A.; Brownjohn, J.M.W.; Taylor, C.A. Measurements of static and dynamic displacement fromvisual monitoring of the Humber Bridge. *Eng. Struct.* 1993, 15, 197-208.
7. Olaszek, P. Investigation of the dynamic characteristic of bridge structures using a computer vision method.*Measurement* 1999, 25, 227-236.
8. Wahbeh, A.M.; Caffrey, J.P.; Masri, S.F. A vision-based approach for the direct measurement of displacementsin vibrating systems. *Smart Mater. Struct.* 2003, 12, 785.
9. Faulkner, B.C. Determination of Bridge Response Using Acceleration Data; Report No. FHWA/VA-97-R5; VirginiaTransportation Research Council: Charlottesville, VA, USA, 1996.
10. Park, K.-T.; Kim, S.-H.; Park, H.-S.; Lee, K.-W. The determination of bridge displacement using measuredacceleration. *Eng. Struct.* 2005, 27, 371-378.
11. Wang, Z.-C.; Geng, D.; Ren, W.-X.; Liu, H.-T. Strain modes based dynamic displacement estimation of beamstructures with strain sensors. *Smart Mater. Struct.* 2014, 23, 125045.
12. Chung, W.; Kim, S.; Kim, N.-S.; Lee, H.-U. Deflection estimation of a full scale prestressed concrete girderusing long-gauge fiber optic sensors. *Constr. Build. Mater.* 2008, 22, 394-401.
13. Glaser, R.; Caccese, V.; Shahinpoor, M. Shape monitoring of a beam structure from measured strain orcurvature. *Exp. Mech.* 2012, 52, 591-606.
14. Kang, L.-H.; Kim, D.-K.; Han, J.-H. Estimation of dynamic structural displacements using fiber Bragg gratingstrain sensors. *J. Sound Vib.* 2007, 305, 534-542.
15. Rapp, S.; Kang, L.-H.; Han, J.-H.; Mueller, U.C.; Baier, H. Displacement field estimation for a two-dimensionalstructure using fiber Bragg grating sensors. *Smart Mater. Struct.* 2009, 18, 025006.
16. Kim, H.-I.; Kang, L.-H.; Han, J.-H. Shape estimation with distributed fiber Bragg grating sensors for rotatingstructures. *Smart Mater. Struct.* 2011, 20, 035011.
17. Kim, N.-S.; Cho, N.-S. Estimating deflection of a simple beam model using fiber optic Bragg-grating sensors.*Exp. Mech.* 2004, 44, 433-439.
18. Moon, H.S.; Ok, S.; Chun, P.-J.; Lim, Y.M. Artificial neural network for vertical displacement prediction of a bridge from strains (Part 1): Girder bridge under moving vehicles. *Appl. Sci.* 2019, 9, 2881.

-
19. Moon, H.S.; Ok, S.; Chun, P.-J.; Lim, Y.M. Artificial neural network for vertical displacement prediction of a bridge from strains (Part 2): Optimization of strain-measurement points by a genetic algorithm under dynamic loading. *Appl. Sci.* 2020, 10, 777.
 20. Yoshua, B.; Ian, J.; Goodfellow; Aaron, C. Deep Learning, Book in preparation for MIT Press, 2015.
 21. Beyer K.; Goldstein J.; Ramakrishnan R.; Shaft U. When is “nearest neighbor” meaningful? *Lect. Notes Comput. Sci.* 1998.
 22. Frank, E.; Bouckaert, R.R.; Naïve Bayes for text classification with unbalanced classes. *European conference on Principles of Data Mining and Knowledge Discovery*. Springer, Berlin, Heidelberg. 2006.
 23. Breiman, L.; Friedman, J.H.; Olshen, R.A.; Stone, C.J. *Classification and Regression Trees*. Routledge. Boca Raton. 2017.
 24. Breiman, L. Random forests. *Mach Learn.* 2001, 45, 5–32.
 25. Breiman, L. Bagging predictors. *Mach Learn.* 1996, 24, 123–140.
 26. Freund, Y.; Schapire, R.E. A short introduction to boosting. *Journal of Japanese Society for Artificial Intelligence*. 1999, 14(5), 771–780.
 27. Chen, T.; Guestrin, C. XGBoost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining*. 2016, 785–794.
 28. Ke, G.; Meng, Q.; Finley, T.; Wang, T.; Chen, W.; Ma, W.; Ye, Q.; Liu, T.Y. LightGBM: A highly efficient gradient boosting decision tree. *Advances in neural information processing systems*. 2017, 30, 3146–3154.
 29. Dorogush, A.V.; Ershov, V.; Gulin, A. CatBoost: gradient boosting with categorical features support. *ArXiv abs/1810.11363*. 2018.
 30. Chen, X.; Topac, T.; Smith, W.; Ladpli, P.; Liu, C.; Chang, F.K. Characterization of Distributed Microfabricated Strain Gauges on Stretchable Sensor Networks for Structural Applications. *Sensors* 2018, 18, 3260.
 31. Glišić, B.; Yao, Y.; Tung, S.T.E.; Wagner, S.; Sturm, J.C.; Verma, N. Strain sensing sheets for structural health monitoring based on large-area electronics and integrated circuits. *Proc. IEEE* 2016, 104, 1513–1528.
 32. Yi, T.H.; Li, H.N.; Zhang, X.D. Health monitoring sensor placement optimization for Canton Tower using immune monkey algorithm. *Struct. Control Health Monit.* 2015, 22, 123–138.
 33. Jung, B.K.; Cho, J.R.; Jeong, W.B. Sensor placement optimization for structural modal identification of flexible structures using genetic algorithm. *J. Mech. Sci. Technol.* 2015, 29, 2775–2783.
 34. Papadimitriou, C. Optimal sensor placement methodology for parametric identification of structural systems. *J. Sound Vib.* 2004, 278, 923–947.
 35. Kincaid, R.K.; Padula, S.L. D-optimal designs for sensor and actuator locations. *Comput. Oper. Res.* 2002, 29, 701–713.
 36. Papadimitriou, C.; Beck, J.L.; Au, S.-K. Entropy-based optimal sensor location for structural model updating. *J. Vib. Control* 2000, 6, 781–800.
-

-
37. Worden, K.; Burrows, A.P. Optimal sensor placement for fault detection. *Eng. Struct.* 2001, 23, 885–901.
 38. Liu, W.; Gao, W.-C.; Sun, Y.; Xu, M.-J. Optimal sensor placement for spatial lattice structure based on geneticalgorithms. *J. Sound Vib.* 2008, 317, 175–189.
 39. Yi, T.-H.; Li, H.-N. Methodology developments in sensor placement for health monitoring of civilinfrastructures. *Int. J. Distrib. Sens. Netw.* 2012, 8, 612726.
 40. Meo, M.; Zumpano, G. On the optimal sensor placement techniques for a bridge structure. *Eng. Struct.* 2005,27, 1488–1497.
 41. Yi, T.-H.; Li, H.-N.; Gu, M. Optimal sensor placement for health monitoring of high-rise structure based ongenetic algorithm. *Math. Probl. Eng.* 2011, 2011, 1–12.
 42. Papadimitriou, C.; Lombaert, G. The effect of prediction error correlation on optimal sensor placement instructural dynamics. *Mech. Syst. Signal Proc.* 2012, 28, 105–127.
 43. Chow, H.M.; Lam, H.F.; Yin, T.; Au, S.K. Optimal sensor configuration of a typical transmission tower for thepurpose of structural model updating. *Struct. Control Health Monit.* 2011, 18, 305–320.
 44. Rao, A.R.M.; Anandakumar, G. Optimal placement of sensors for structural system identification and healthmonitoring using a hybrid swarm intelligence technique. *Smart Mater. Struct.* 2007, 16, 2658.
 45. Rapaic, M.; Kanovic, Z.; Jelcic, Z. Discrete particle swarm optimization algorithm for solving optimal sensordeployment problem. *J. Autom. Control* 2008, 18, 9–14.
 46. Kukunuru, N.; Thella, B.R.; Davuluri, R.L. Sensor deployment using particle swarm optimization. *Int. J. Eng.Sci. Technol.* 2010, 2, 5395–5401.
 47. Dutta, R.; Ganguli, R.; Mani, V. Swarm intelligence algorithms for integrated optimization of piezoelectricactuator and sensor placement and feedback gains. *Smart Mater. Struct.* 2011, 20, 105018.
 48. Yi, T.-H.; Li, H.-N.; Zhang, X.-D. A modified monkey algorithm for optimal sensor placement in structuralhealth monitoring. *Smart Mater. Struct.* 2012, 21, 105033.
 49. Yi, T.-H.; Li, H.-N.; Gu, M. A new method for optimal selection of sensor location on a high-rise buildingusing simplified finite element model. *Struct. Eng. Mech.* 2011, 37, 671–684.
 50. McCulloch, W.S.; Pitts, W. A logical calculus of the ideas immanent in nervous activity. *Bull. Math. Biophys.*1943, 5, 115–133.
 51. Cook, D.F.; Ragsdale, C.T.; Major, R.L. Combining a neural network with a genetic algorithm for processparameter optimization. *Eng. Appl. Artif. Intell.* 2000, 13, 391–396.
 52. Momeni, E.; Nazir, R.; Armaghani, D.J.; Maizir, H. Prediction of pile bearing capacity using a hybrid geneticalgorithm-based ANN. *Measurement* 2014, 57, 122–131.
 53. Chen, H.; Zeng, Z. Deformation prediction of landslide based on improved back-propagation neural network.*Cogn. Comput.* 2013, 5, 56–62.
 54. Benardos, P.G.; Vosniakos, G.-C. Optimizing feedforward artificial neural network architecture. *Eng. Appl.Artif. Intell.* 2007, 20, 365–382.
 55. Yan, F.; Lin, Z.; Wang, X.; Azarmi, F.; Sobolev, K. Evaluation and prediction of bond strength of GFRP-barreinforced concrete using artificial neural network optimized with genetic algorithm. *Compos. Struct.* 2017,161, 441–452.
-

-
56. Najjar, Y.M.; Basheer, I.A. Utilizing computational neural networks for evaluating the permeability of compacted clay liners. *Geotech. Geol. Eng.* 1996, 14, 193–212.
 57. Shahin, M.A.; Maier, H.R.; Jaksa, M.B. Predicting settlement of shallow foundations using neural networks. *J. Geotech. Geoenviron. Eng.* 2002, 128, 785–793.
 58. Jan, J.C.; Hung, S.-L.; Chi, S.Y.; Chern, J.C. Neural network forecast model in deep excavation. *J. Comput. Civ. Eng.* 2002, 16, 59–65.
 59. Holland, J.H. *Adaptation in Natural and Artificial Systems*; The University of Michigan Press: Ann Arbor, MI, USA, 1975.
 60. Mohamad, E.T.; Faradonbeh, R.S.; Armaghani, D.J.; Monjezi, M.; Majid, M.Z.A. An optimized ANN model based on genetic algorithm for predicting ripping production. *Neural Comput. Appl.* 2017, 28, 393–406.
 61. Osyczka, A. *Evolutionary Algorithms for Single and Multicriteria Design Optimization*; Physica: Heidelberg, Germany, 2002.
 62. Faghihi, V.; Reinschmidt, K.F.; Kang, J.H. Construction scheduling using genetic algorithm based on building information model. *Expert Syst. Appl.* 2014, 41, 7565–7578.
 63. Chandwani, V.; Agrawal, V.; Nagar, R. Modeling slump of ready mix concrete using genetic algorithm assisted training of Artificial Neural Networks. *Expert Syst. Appl.* 2015, 42, 885–893.
 64. RazaviAlavi, S.; AbouRizk, S. Site layout and construction plan optimization using an integrated genetic algorithm simulation framework. *J. Comput. Civ. Eng.* 2017, 31, 04017011.
 65. Woodward, R.I.; Kelleher, E.J.R. Towards ‘smart lasers’: Self-optimisation of an ultrafast pulse source using a genetic algorithm. *Sci. Rep.* 2016, 6, 37616.
 66. Zhang, G.; Patuwo, B.E.; Hu, M.Y. Forecasting with artificial neural networks: The state of the art. *Int. J. Forecast.* 1998, 14, 35–62.
 67. Zuo, L.; Nayfeh, S.A. Structured H2 optimization of vehicle suspensions based on multi-wheel models. *Veh. Syst. Dyn.* 2003, 40, 351–371.
 68. Ahmed, K.A.; Abdelhady, M.B.A.; Abouelnour, A.M.A.A. The improvement of ride comfort of a city bus which is fabricated on a lorry chassis. *Eng. Res. J.* 1997, 53, 19–35.
 69. Li, H. *Dynamic Response of Highway Bridges Subjected to Heavy Vehicles*; The Florida State University: Tallahassee, FL, USA, 2005.
 70. Chun, B.-J. *Skewed Bridge Behaviors: Experimental, Analytical, and Numerical Analysis*. Ph.D. Thesis, Wayne State University, Detroit, MI, USA, 2010.
 71. Ok, S.Y.; Moon, H.S.; Chun, P.-J.; Lim, Y.M. Estimation of dynamic vertical displacement using artificial neural network and axial strain in girder bridge. *J. Korean Soc. Civ. Eng.* 2014, 34, 1655–1665.
 72. Mathew, T.V. *Vehicle Arrival Models: Headway*. In *Transportation Systems Engineering*; Chapter 12; Retrieved from website of National Programme on Technology Enhanced Learning (NPTEL); Indian Institute of Technology: Bombay, India, 2014.
-

< 별첨 >

별첨 자료

1. 총 연구개발기간 성과점검기준표 및 증빙자료
2. 세부 정량적 연구개발성과 증빙자료(총 연구개발기간 성과점검기준표 실적 증빙자료에 기 포함되어 있는 증빙자료 제외)

주 의

1. 이 보고서는 국토교통부에서 시행한 국토교통과학기술 연구개발사업 ‘국토교통기술촉진연구사업’ 연구개발과제 최종보고서이다.
2. 이 연구개발내용을 대외적으로 발표할 때에는 반드시 국토교통부(국토교통과학기술진흥원)에서 시행한 국토교통과학기술 연구개발사업의 결과임을 밝혀야 한다.
3. 국가과학기술 기밀 유지에 필요한 내용은 대외적으로 발표 또는 공개하여서는 안 된다.